

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Ivan Nemčić

Zagreb, 2016.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKIRAD

Mentor:

Prof. dr. sc. Janoš Kodvanj, dipl. ing.

Student:

Ivan Nemčić

Zagreb, 2016.

Izjavljujem da sam ovaj rad izradio samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.

Najprije, iznimno se zahvaljujem svom mentoru prof.dr.sc. Janošu Kodvanju koji mi je omogućio suradnju s dr.sc. Zvonimirom Tomičevićem. Također, veliko hvala na korisnim savjetima, usmjeravanju, ohrabrivanju i podizanju radne atmosfere u svakoj prilici. Svojom osobnošću, pozitivnim stavom i veselim duhom poticao me na daljnji rad u trenucima kad mi je bilo najviše potrebno.

Posebnu zahvalnost dugujem dr.sc. Zvonimiru Tomičeviću koji me je svojim entuzijazmom zainteresirao za odabir područja eksperimentalne mehanike i optičkih metoda te mi omogućio bavljenje ovom aktualnom tematikom. Zahvaljujem se na uloženom vremenu, trudu i povjerenju te korisnim savjetima koji su mi pružili potrebna znanja za izradu ovog rada. Također, hvala na razumijevanju, strpljenju, podršci i nevjerojatnoj dostupnosti koji su mi bili prijeko potrebni u najtežim trenucima izrade rada.

Iskreno se zahvaljujem i asistentu Damjanu Čakmaku, mag. ing. stroj. na nesebičnoj pomoći, objašnjenjima i savjetima kod problema identificiranja materijalnog modela i kalibriranja (prilagodbe) odabranog modela eksperimentalnim podacima, i svim ostalim prijateljskim savjetima koji su mi olakšali izradu rada.

Zahvaljujem se i prof. dr. sc. Igoru Karšaju na savjetima pri odabiru literature.

Isto tako zahvalio bih se i svim ostalim djelatnicima Laboratorija za eksperimentalnu mehaniku na ugodnim konstruktivnim razgovorima i društvu.

Svim srcem zahvaljujem se svojoj obitelji, ocu Mladenu, majci Kseniji, sestrama Antoniji i Ivoni, na nemjerljivoj podršci tijekom mog dosadašnjeg školovanja i svemu potrebnom u utrci za ostvarenjem životnih ciljeva.

Zahvaljujem i svim svojim dugogodišnjim prijateljima i kolegama s fakulteta na druženju, savjetima i pomoći u svim oblicima. Zajedno smo bili uporniji i problemi su se lakše rješavali.

Ivan Nemčić



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za diplomske ispite studija strojarstva za smjerove:
procesno-energetski, konstrukcijski, brodstrojarski i inženjersko modeliranje i računalne simulacije

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

DIPLOMSKI ZADATAK

Student:

Ivan NEMČIĆ

Mat. br.: 0035178844

Naslov rada na
hrvatskom jeziku:

Primjena optičkih metoda za određivanje ponašanja bioloških mekih tkiva pri ravninskom dvoosnom opterećenju

Naslov rada na
engleskom jeziku:

Application of optical methods to assess the material response of soft tissues subjected under in-plane biaxial loading regime

Opis zadatka:

Bolesti srca i krvnih žila predstavljaju jedan od najvećih medicinskih problema suvremenog svijeta i jedan su od vodećih uzroka smrtnosti u razvijenim zemljama. Kako bi se bolje razumijele posljedice bolesti krvnih žila postoji potreba za provedbom mehaničkih ispitivanja s ciljem određivanja pouzdanijih materijalnih svojstava. Kod pretkliničkih istraživanja krvnih žila koriste se životinjski modeli. Mnoga istraživanja su provedena na modelima svinjskih žila pošto se pokazalo da su određene fiziološke i anatomske značajke vrlo slične ljudskim žilama.

U radu je potrebno analizirati četiri ravninska dvoosna eksperimenta na modelima pripremljenim od svinjske aorte. Na tri uzorka mjerenje deformacija provesti korištenjem videoekstenzometra i metode korelacije digitalne slike (DIC). Videoekstenzometrom je potrebno pratiti pomake dvaju markera po svakoj osi opterećenja, dok kod metode korelacije digitalne slike analizu cijelog polja pomaka provesti na uzorku s umjetnom teksturom između markera. Polja deformacija izmjerena DIC metodom usporediti s deformacijama dobivenim videoekstenzometrom. Kod četvrtog uzorka pomake i deformacije odrediti samo DIC metodom na cijeloj površini uzorka kako bi se odredio utjecaj prihvata na izmjereno polje pomaka i deformacija.

Tijekom rada potrebno je:

1. Upoznati se s radom videoekstenzometra i regularizacijskom metodom korelacije digitalne slike.
2. Pošto je tijekom ispitivanja ispitni uzorak uronjen u PBS tekućinu potrebno je provesti parametarsku analizu rezolucije pomaka kako bi se odredili regularizacijski parametri za dobivanje najpouzdanijih rezultata.
3. Odrediti cijelo polje pomaka i deformacija koristeći RT3-DIC algoritam. Optičkim ekstenzometrom potrebno je izračunati prosječne vrijednosti komponenta deformacija.
4. Identificirati parametre materijala za hiperelastični materijalni model (Mooney-Rivlin).

U radu navesti korištenu literaturu i eventualno dobivenu pomoć.

Zadatak zadan:

Rok predaje rada:

Predviđeni datumi obrane:

14. siječnja 2016.

17. ožujka 2016.

23., 24. i 25. ožujka 2016.

Zadatak zadao:

Predsjednica Povjerenstva:


Prof. dr. sc. Janoš Kodvanj


Prof. dr. sc. Tanja Jurčević Lulić

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA	III
POPIS TABLICA.....	VIII
POPIS OZNAKA	IX
SAŽETAK.....	XI
SUMMARY	XII
1. UVOD.....	1
1.1. Motivacija	1
1.2. Pregled dosadašnjih istraživanja	2
1.3. Ciljevi i hipoteze istraživanja.....	5
1.4. Očekivani znanstveni doprinos	6
1.5. Struktura rada	7
2. KRVOŽILNI SUSTAV ČOVJEKA.....	9
2.1. Krvne žile.....	9
2.2. Krvni tlak	11
2.3. Građa krvnih žila.....	12
2.4. Bolesti krvožilnog sustava	13
3. ŽIVOTINJSKI MODELI ZA PRETKLINIČKA ISTRAŽIVANJA.....	14
3.1. Usporedba anatomije svinjskog i ljudskog krvožilnog tkiva	14
3.2. Usporedba mehaničkih karakteristika svinjskog i ljudskog krvožilnog tkiva	15
4. MATERIJALNI MODELI	21
4.1. Odabir konstitutivnog materijalnog modela	21
4.2. Hiperelastični materijalni modeli.....	22
4.2.1. Vrste hiperelastičnih modela.....	23
4.2.1.1. Materijalni model Neo-Hooke	25
4.2.1.2. Materijalni model Mooney-Rivlin	25
4.2.1.3. Materijalni model Ogden	25
4.2.2. Kalibracija hiperelastičnih modela.....	26
4.2.3. Druckerov kriterij stabilnosti	27
5. METODOLOGIJA	29
5.1. Ekstenzometar	29
5.2. Korelacija digitalne slike	36
5.2.1. Oprema za DIC	36
5.2.2. Koncepti DIC metode	38
5.3. Verifikacija odabranih hiperelastičnih materijalnih modela i određivanje parametara materijala.....	45
5.3.1. Uvod u MCalibration	45
6. PARAMETARSKA ANALIZA REZOLUCIJE POMAKA.....	48
7. EKSPERIMENTALNO ISPITIVANJE	51

7.1.	Program opterećenja ispitnog uzorka.....	51
7.2.	Priprema uzoraka	53
7.3.	Provedba dvoosnog vlačnog ispitivanja.....	57
7.3.1.	Podešavanje i kalibracija sustava.....	59
7.3.2.	Mehaničko ispitivanje	59
7.3.3.	Određivanje mjerne nesigurnosti	61
8.	REZULTATI	64
8.1.	Eksperimentalni rezultati za ispitni uzorak AORTA 1	64
8.2.	Usporedba rezultata uzoraka AORTA 1, AORTA 2 i AORTA 3	80
8.3.	Utjecaj prihvata na homogenost polja pomaka i deformacija.....	82
8.4.	Diskusija.....	83
9.	IDENTIFIKACIJA PARAMETARA MATERIJALA ZA HIPERELASTIČNI MATERIJALNI MODEL.....	86
9.1.	Kalibracija hiperelastičnog materijalnog modela: <i>neo – Hooke</i>	86
9.2.	Kalibracija hiperelastičnog materijalnog modela: <i>Mooney – Rivlin</i>	87
9.3.	Kalibracija hiperelastičnog materijalnog modela: <i>Ogden</i>	89
9.4.	Diskusija.....	92
10.	ZAKLJUČAK.....	93
	LITERATURA.....	95
	PRILOZI.....	99

POPIS SLIKA

Slika 1.	Raspodjela krvi po dijelovima krvožilnog sustava [27]	10
Slika 2.	Normalni krvni tlakovi u pojedinim dijelovima krvožilnog sustava [27]	11
Slika 3.	Građa krvnih žila [28]	12
Slika 4.	Dijagrami ovisnosti vanjskog promjera žile i aksijalne sile o tlaku na stijenku žile (koronarne arterije) [29]	17
Slika 5.	Dijagrami ovisnosti vanjskog promjera žile i aksijalne sile o tlaku na stijenku žile (prsne arterije) [29]	18
Slika 6.	Usporedba odnosa cirkularnog naprezanja u ovisnosti o cirkularnoj deformaciji za ljudske i svinjske arterije [29]	19
Slika 7.	Usporedba odnosa aksijalnog naprezanja u ovisnosti o cirkularnoj deformaciji za ljudske i svinjske arterije [29]	19
Slika 8.	Statički pokus: a) jednoosni, b) dvoosni, c) ravninsko stanje deformacija [39] ...	24
Slika 9.	Mjerenje „clip on“ ekstenzometrom [46]	30
Slika 10.	Mjerenje „sensor arm“ ekstenzometrom [48]	30
Slika 11.	Mjerenje laserskim ekstenzometrom [48]	31
Slika 12.	Mjerenje pomaka videoekstenzometrom	33
Slika 13.	Primjer crno – bijele slike uzorka korištene u analizi pomaka i deformacija videoekstenzometrom	34
Slika 14.	Linija mjerenja	34
Slika 15.	Prepoznavanje bijelih uzoraka na liniji mjerenja: a) svi uzorci vidljivi na liniji mjerenja, b) odabrani markeri	35
Slika 16.	Oprema za DIC metodu	37
Slika 17.	Detekcija piksela poljem piksela [50]	38
Slika 18.	Primjer stohastičkog rastera nanesenog na ispitni uzorak i označeno polje piksela na referentnoj (a) i deformiranoj slici (b)	39
Slika 19.	Referentna i deformirana konfiguracija	39
Slika 20.	Primjer diskretizacije ROI-a T3 trokutastim elementima na referentnoj (a) i deformiranoj slici (b)	44
Slika 21.	Odabir seta podataka (a), primjer učitanih podataka (b)	45
Slika 22.	Odabir postavki za učitane podatke	46
Slika 23.	Odabir vrste opterećenja	47
Slika 24.	Odabir materijalnog modela	47
Slika 25.	Standardna greška pomaka za različite regularizacijske dužine i različite omjere l_b/l_m u smjeru osi x (a) i u smjeru osi y (b) [24]	48
Slika 26.	Promjena standardne greške pomaka za različite regularizacijske dužine l_m uz omjer $l_b/l_m=1/2$ u smjeru osi x (a) i u smjeru osi y (b)	49
Slika 27.	Polja reziduala (grešaka) kod $l_m=1$ piksel s početnom regularizacijskom dužinom $l_m=128$ piksela (a) i $l_m=1024$ piksela (b) [52]	50
Slika 28.	Polja reziduala (grešaka) kod $l_m=1$ piksel s početnom regularizacijskom dužinom $l_m=128$ piksela za uzorak AORTA 1	50
Slika 29.	Shematski prikaz ravninskog dvoosnog ispitivanja uzorka svinjske aorte	53
Slika 30.	Svinjska aorta	54
Slika 31.	Seciranje žile	54
Slika 32.	Uzorak svinjske aorte	55
Slika 33.	Orijentacija uzoraka AORTA 1, 2 i 4	55

Slika 34.	Orijentacija uzorka AORTA 3	56
Slika 35.	Primjeri rastera na uzorcima: a) uzorci AORTA1, 2 i 3, b) uzorak AORTA4	57
Slika 36.	Eksperimentalni postav	58
Slika 37.	Uzorak postavljen na stroj i potopljen u PBS otopinu	58
Slika 38.	Kalibracija mjernog sustava	59
Slika 39.	a) <i>Prekondicioniranje 1</i> , b) <i>Test 1</i>	60
Slika 40.	a) <i>Prekondicioniranje 2</i> , b) <i>Test 2</i>	60
Slika 41.	Usporedni prikaz standardnog odstupanja pomaka u za uzorak AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	62
Slika 42.	Usporedni prikaz standardnog odstupanja deformacije ε za uzorak AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	63
Slika 43.	Usporedni prikaz promjene deformacije ε u vremenu t za <i>Prekondicioniranje 1</i> uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	65
Slika 44.	Dijagram promjene sile F za <i>Prekondicioniranje 1</i> uzorka AORTA 1 u aksijalnom (A) i transverzalnom (T) smjeru	66
Slika 45.	Usporedni prikaz promjene deformacija ε za <i>Prekondicioniranje 1</i> uzorka AORTA 1	66
Slika 46.	Dijagram sila F – deformacija ε za <i>Prekondicioniranje 1</i> uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	67
Slika 47.	Mjerena polja deformacija za vršne vrijednosti opterećenja za <i>Prekondicioniranje 1</i> uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	68
Slika 48.	Usporedni prikaz promjene deformacije ε u vremenu t za <i>Test 1</i> uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	69
Slika 49.	Dijagram promjene sile F za <i>Test 1</i> uzorka AORTA 1 u aksijalnom (A) i transverzalnom (T) smjeru	70
Slika 50.	Usporedni prikaz promjene deformacija ε za <i>Test 1</i> uzorka AORTA 1	71
Slika 51.	Dijagram sila F – deformacija ε za <i>Test 1</i> uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	71
Slika 52.	Mjerena polja pomaka za vršnu vrijednost opterećenja za <i>Test 1</i> uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	72
Slika 53.	Mjerena polja deformacija za vršnu vrijednost opterećenja za <i>Test 1</i> uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	72
Slika 54.	Usporedni prikaz promjene deformacije ε u vremenu t za <i>Prekondicioniranje 2</i> uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	73
Slika 55.	Dijagram promjene sile F za <i>Prekondicioniranje 2</i> uzorka AORTA 1 u aksijalnom (A) i transverzalnom (T) smjeru	74
Slika 56.	Usporedni prikaz promjene deformacija ε za <i>Prekondicioniranje 2</i> uzorka AORTA 1	74
Slika 57.	Dijagram sila F – deformacija ε za <i>Prekondicioniranje 2</i> uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	75
Slika 58.	Mjerena polja deformacija za vršne vrijednosti opterećenja za <i>Prekondicioniranje 2</i> uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	76
Slika 59.	Usporedni prikaz promjene deformacije ε u vremenu t za <i>Test 2</i> uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	77

Slika 60.	Dijagram promjene sile F za <i>Test 2</i> uzorka AORTA 1 u aksijalnom (A) i transverzalnom (T) smjeru	78
Slika 61.	Usporedni prikaz promjene deformacija ε za <i>Test 2</i> uzorka AORTA 1	78
Slika 62.	Dijagram sila F – deformacija ε za <i>Test 2</i> uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	79
Slika 63.	Mjerena polja pomaka za vršnu vrijednost opterećenja za <i>Test 2</i> uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru.....	79
Slika 64.	Mjerena polja deformacija za vršnu vrijednost opterećenja za <i>Test 2</i> uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	80
Slika 65.	Dijagrami opterećenja uzoraka AORTA 1, AORTA 2 i AORTA 3 u aksijalnom (A) i transverzalnom (T) smjeru.....	81
Slika 66.	Dijagrami opterećenja uzoraka AORTA 1, AORTA 2 i AORTA 3 u aksijalnom (A) i transverzalnom (T) smjeru.....	82
Slika 67.	Mjerena polja pomaka za vršnu vrijednost opterećenja za <i>Test 2</i> uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru.....	83
Slika 68.	Mjerena polja deformacija za vršnu vrijednost opterećenja za <i>Test 2</i> uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	83
Slika 69.	Kalibracija <i>neo – Hooke</i> materijalnog modela za dvoosno stanje naprezanja	86
Slika 70.	Provjera Druckerovog kriterija stabilnosti za <i>neo – Hooke</i> materijalni model	87
Slika 71.	Kalibracija <i>Mooney – Rivlin</i> materijalnog modela za dvoosno stanje naprezanja	88
Slika 72.	Provjera Druckerovog kriterija stabilnosti za <i>Mooney – Rivlin</i> materijalni model.....	88
Slika 73.	Kalibracija <i>Ogden</i> ($N=1$) materijalnog modela pri dvoosnom stanju naprezanja	89
Slika 74.	Provjera Druckerovog kriterija stabilnosti za <i>Ogden</i> ($N=1$) materijalni model ...	90
Slika 75.	Kalibracija <i>Ogden</i> ($N=2$) materijalnog modela za dvoosno stanje naprezanja	90
Slika 76.	Provjera Druckerovog kriterija stabilnosti za <i>Ogden</i> ($N=2$) materijalni model	91
Slika 77.	Usporedni prikaz promjene deformacije ε u vremenu t za <i>Prekondicioniranje 1</i> uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	100
Slika 78.	Dijagram promjene sile F za <i>Prekondicioniranje 1</i> uzorka AORTA 2 u aksijalnom (A) i transverzalnom (T) smjeru.....	100
Slika 79.	Usporedni prikaz promjene deformacija ε za <i>Prekondicioniranje 1</i> uzorka AORTA 2	101
Slika 80.	Dijagram sila F – deformacija ε za <i>Prekondicioniranje 1</i> uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	101
Slika 81.	Usporedni prikaz promjene deformacije ε u vremenu t za <i>Test 1</i> uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	102
Slika 82.	Dijagram promjene sile F za <i>Test 1</i> uzorka AORTA 2 u aksijalnom (A) i transverzalnom (T) smjeru	102
Slika 83.	Usporedni prikaz promjene deformacija ε za <i>Test 1</i> uzorka AORTA 2.....	103
Slika 84.	Dijagram sila F – deformacija ε za <i>Test 1</i> uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	103
Slika 85.	Mjerena polja pomaka za vršnu vrijednost opterećenja za <i>Test 1</i> uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru.....	104
Slika 86.	Mjerena polja deformacija za vršnu vrijednost opterećenja za <i>Test 1</i> uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	104
Slika 87.	Usporedni prikaz promjene deformacije ε u vremenu t za <i>Prekondicioniranje 2</i> uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	105

Slika 88.	Dijagram promjene sile F za <i>Prekondicioniranje 2</i> uzorka AORTA 2 u aksijalnom (A) i transverzalnom (T) smjeru.....	105
Slika 89.	Usporedni prikaz promjene deformacija ε za <i>Prekondicioniranje 2</i> uzorka AORTA 2	106
Slika 90.	Dijagram sila F – deformacija ε za <i>Prekondicioniranje 2</i> uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	106
Slika 91.	Usporedni prikaz promjene deformacije ε u vremenu t za <i>Test 2</i> uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	107
Slika 92.	Dijagram promjene sile F za <i>Test 2</i> uzorka AORTA 2 u aksijalnom (A) i transverzalnom (T) smjeru	107
Slika 93.	Usporedni prikaz promjene deformacija ε za <i>Test 2</i> uzorka AORTA 2.....	108
Slika 94.	Dijagram sila F – deformacija ε za <i>Test 2</i> uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	108
Slika 95.	Mjerena polja pomaka za vršnu vrijednost opterećenja za <i>Test 2</i> uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru.....	109
Slika 96.	Mjerena polja deformacija za vršnu vrijednost opterećenja za <i>Test 2</i> uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	109
Slika 97.	Usporedni prikaz promjene deformacije ε u vremenu t za <i>Prekondicioniranje 1</i> uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	110
Slika 98.	Dijagram promjene sile F za <i>Prekondicioniranje 1</i> uzorka AORTA 3 u aksijalnom (A) i transverzalnom (T) smjeru.....	110
Slika 99.	Usporedni prikaz promjene deformacija ε za <i>Prekondicioniranje 1</i> uzorka AORTA 3	111
Slika 100.	Dijagram sila F – deformacija ε za <i>Prekondicioniranje 1</i> uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	111
Slika 101.	Usporedni prikaz promjene deformacije ε u vremenu t za <i>Test 1</i> uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	112
Slika 102.	Dijagram promjene sile F za <i>Test 1</i> uzorka AORTA 3 u aksijalnom (A) i transverzalnom (T) smjeru	112
Slika 103.	Usporedni prikaz promjene deformacija ε za <i>Test 1</i> uzorka AORTA 3.....	113
Slika 104.	Dijagram sila F – deformacija ε za <i>Test 1</i> uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	113
Slika 105.	Mjerena polja pomaka za vršnu vrijednost opterećenja za <i>Test 1</i> uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru.....	114
Slika 106.	Mjerena polja deformacija za vršnu vrijednost opterećenja za <i>Test 1</i> uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	114
Slika 107.	Usporedni prikaz promjene deformacije ε u vremenu t za <i>Prekondicioniranje 2</i> uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	115
Slika 108.	Dijagram promjene sile F za <i>Prekondicioniranje 2</i> uzorka AORTA 3 u aksijalnom (A) i transverzalnom (T) smjeru.....	115
Slika 109.	Usporedni prikaz promjene deformacija ε za <i>Prekondicioniranje 1</i> uzorka AORTA 3	116
Slika 110.	Dijagram sila F – deformacija ε za <i>Prekondicioniranje 2</i> uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	116

Slika 111.	Usporedni prikaz promjene deformacije ε u vremenu t za <i>Test 2</i> uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	117
Slika 112.	Dijagram promjene sile F za <i>Test 2</i> uzorka AORTA 3 u aksijalnom (A) i transverzalnom (T) smjeru	117
Slika 113.	Usporedni prikaz promjene deformacija ε za <i>Test 2</i> uzorka AORTA 3.....	118
Slika 114.	Dijagram sila F – deformacija ε za <i>Test 2</i> uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	118
Slika 115.	Mjerena polja pomaka za vršnu vrijednost opterećenja za <i>Test 2</i> uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru.....	119
Slika 116.	Mjerena polja deformacija za vršnu vrijednost opterećenja za <i>Test 2</i> uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	119
Slika 117.	Usporedni prikaz promjene deformacije ε u vremenu t za <i>Prekondicioniranje 1</i> uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	120
Slika 118.	Dijagram promjene sile F za <i>Prekondicioniranje 1</i> uzorka AORTA 4 u aksijalnom (A) i transverzalnom (T) smjeru.....	120
Slika 119.	Usporedni prikaz promjene deformacija ε za <i>Prekondicioniranje 1</i> uzorka AORTA 4	121
Slika 120.	Dijagram sila F – deformacija ε za <i>Prekondicioniranje 1</i> uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	121
Slika 121.	Usporedni prikaz promjene deformacije ε u vremenu t za <i>Test 1</i> uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	122
Slika 122.	Dijagram promjene sile F za <i>Test 1</i> uzorka AORTA 4 u aksijalnom (A) i transverzalnom (T) smjeru	122
Slika 123.	Usporedni prikaz promjene deformacija ε za <i>Test 1</i> uzorka AORTA 4.....	123
Slika 124.	Dijagram sila F – deformacija ε za <i>Test 1</i> uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	123
Slika 125.	Mjerena polja pomaka za vršnu vrijednost opterećenja za <i>Test 1</i> uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru.....	124
Slika 126.	Mjerena polja deformacija za vršnu vrijednost opterećenja za <i>Test 1</i> uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	124
Slika 127.	Usporedni prikaz promjene deformacije ε u vremenu t za <i>Prekondicioniranje 2</i> uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	125
Slika 128.	Dijagram promjene sile F za <i>Prekondicioniranje 2</i> uzorka AORTA 4 u aksijalnom (A) i transverzalnom (T) smjeru.....	125
Slika 129.	Usporedni prikaz promjene deformacija ε za <i>Prekondicioniranje 2</i> uzorka AORTA 4	126
Slika 130.	Dijagram sila F – deformacija ε za <i>Prekondicioniranje 2</i> uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	126
Slika 131.	Usporedni prikaz promjene deformacije ε u vremenu t za <i>Test 2</i> uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar	127
Slika 132.	Dijagram promjene sile F za <i>Test 2</i> uzorka AORTA 4 u aksijalnom (A) i transverzalnom (T) smjeru	127
Slika 133.	Usporedni prikaz promjene deformacija ε za <i>Test 2</i> uzorka AORTA 4.....	128
Slika 134.	Dijagram sila F – deformacija ε za <i>Test 2</i> uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru	128

POPIS TABLICA

Tablica 1.	Broj čvorova u mreži svakog uzorka.....	44
Tablica 2.	Debljine uzoraka.....	57
Tablica 3.	Vrijednosti maksimalnih sila.....	61
Tablica 4.	Prosječne vrijednosti standardnog odstupanja pomaka i deformacija u smjeru osi A i T za AORTU 1 za videoekstenzometar i DIC.....	63
Tablica 5.	Parametar materijala i koeficijent R^2 za <i>neo – Hooke</i> materijalni model pri dvoosnom stanju naprezanja.....	87
Tablica 6.	Parametri materijala i koeficijent R^2 za <i>Mooney – Rivlin</i> materijalni model pri dvoosnom stanju naprezanja	88
Tablica 7.	Parametri materijala i koeficijent R^2 za <i>Ogden</i> ($N=1$) materijalni model pri dvoosnom stanju naprezanja	89
Tablica 8.	Parametri materijala i koeficijent determinacije za <i>Ogden</i> ($N=2$) materijalni model pri dvoosnom stanju naprezanja	91
Tablica 9.	Vrijednosti koeficijenta R^2 i stabilnost korištenih materijalnih modela	92

POPIS OZNAKA

Oznaka	Jedinica	Opis
a	-	bezdimenzijski parametar
A	mm^2	površina uzorka
b	-	bezdimenzijski parametar
\mathbf{B}	-	lijevi Cauchy – Greenov tenzor deformiranosti
C	-	korelacijski koeficijent
\mathbf{C}	-	Desni Cauchy – Greenov tenzor deformiranosti
C_{01}	-	parametar materijala
C_{10}	-	parametar materijala
f	-	funkcija raspodjele intenziteta sive boje u referentnoj konfiguraciji
\bar{f}	-	srednja vrijednost matrice \mathbf{F}
\mathbf{F}	-	matrica intenziteta nijansi sive boje u referentnoj konfiguraciji
\mathbf{f}	-	vektor čvornih sila
F	N	sila
\mathbf{F}	-	gradijent deformiranja
g	-	funkcija raspodjele intenziteta sive boje u deformiranoj konfiguraciji
\bar{g}	-	srednja vrijednost matrice \mathbf{G}
\mathbf{G}	-	matrica intenziteta nijansi sive boje u deformiranoj konfiguraciji
I_1	-	prva invarijanta desnog Cauchy – Greenovog tenzora deformiranosti \mathbf{C}
I_2	-	druga invarijanta desnog Cauchy – Greenovog tenzora deformiranosti \mathbf{C}
J	-	Jacobijeva determinanta
\mathbf{K}	-	matrica krutosti
L	mm	duljina
L_0	mm	početna duljina
l_b	-	regularizacijska dužina vanjskih čvorova
l_m	-	regularizacijska dužina unutrašnjih čvorova
m	-	broj piksela u vertikalnom smjeru
n	-	broj piksela u horizontalnom smjeru
s_u	-	standardno odstupanje pomaka
s_ε	-	standardno odstupanje deformacije

t	mm	debljina uzorka
u	mm	pomak
u	mm	pomak
\mathbf{u}	-	polje pomaka
u_n	-	stupnjevi slobode polja pomaka
\mathbf{x}	-	matrica lokacije piksela
x, y	-	koordinate točke u referentnoj konfiguraciji
x', y'	-	koordinate točke u deformiranoj konfiguraciji
Z	-	funkcija preslikavanja iz referentne u deformiranu konfiguraciju
α_1	-	parametar materijala
ΔL	mm	promjena duljine
ε	-	inženjerska deformacija
λ	-	glavne (svojstvene) vrijednosti tenzora gradijenta deformiranja
σ	MPa	inženjersko naprezanje
μ_1	-	parametar materijala
ψ_n	-	funkcija oblika
Φ_c^2	-	korelacijski rezidual
Φ_m^2	-	ravnotežna razlika
Φ_b^2	-	rubne fluktuacije
Φ_t^2	-	totalni funkcional

SAŽETAK

Bolesti srca i krvnih žila predstavljaju jedan od najvećih medicinskih problema suvremenog svijeta i jedan su od vodećih uzroka smrtnosti u razvijenim zemljama. Kako bi se bolje razumijele posljedice bolesti krvnih žila postoji potreba za provedbom mehaničkih ispitivanja s ciljem određivanja pouzdanijih materijalnih svojstava krvožilnog tkiva.

U radu su analizirana četiri ravninska dvoosna eksperimenta na uzorcima pripremljenim od svinjske aorte. Na tri uzorka mjerenje deformacija provedeno je videoekstenzometrom i metodom korelacije digitalne slike (DIC). Videoekstenzometrom su praćeni pomaci dvaju markera na uzorku, po svakoj osi opterećenja. DIC metodom je analizirano cijelo polje pomaka površine uzoraka s umjetnom teksturom. Primjenom virtualnog/optičkog ekstenzometra uspoređeni su rezultati dobiveni videoekstenzometrom. Kod četvrtog uzorka RT3-DIC algoritmom određena su polja pomaka i deformacija na cijeloj površini uzorka kako bi se odredio utjecaj eksperimentalnog postava. Dobiveni rezultati pokazali su da DIC metoda rezultira manjom mjernom nesigurnošću zbog uzimanja u obzir kontinuiranosti polja pomaka. Eksperimentalno ispitivanje na predloženom biološki mekom tkivu zabilježilo je veću krutost u smjeru vlakana. Iz provedenih mjerenja za jedan ispitni uzorak određeni su parametri materijala za tri hiperelastična konstitutivna modela. Analizirani su materijalni modeli *neo – Hooke*, *Mooney – Rivlin* i *Ogden*. Usporedbom standardne greške između eksperimentalnih podataka i identificiranih krivulja te provjerom uvjeta Druckerovog kriterija stabilnosti može se zaključiti da konstitutivni zakon *Ogden* polinomske forme prvog reda najpouzdanije opisuje dvoosno ponašanje ispitivanog materijala.

Ključne riječi: aorta, ravninski dvoosni eksperiment, videoekstenzometar, metoda korelacije digitalne slike, hiperelastični materijalni model

SUMMARY

Cardiovascular diseases are one of the biggest medical problems of the modern world and one of the leading causes of death in developed countries. In order to better understand the consequences of vascular diseases there is a need for the implementation of mechanical tests in order to determine reliable properties of cardiovascular tissues.

In this work four planar biaxial experiments have been analyzed on specimens prepared from porcine aorta. On three samples strain data was accessed using the videoekstenzometer and Digital Image Correlation Method (DIC). By means of videoextensometer displacements of two markers were tracked for each sample on each loading axis. As a full-field measurement technique, DIC method was applied to measure displacements/strain fields on surface of the samples. A virtual/optical strain gauge was used to determine mean strain components. Latter were compared videoextensometer measurements. At fourth specimen the whole surface was taken into account to obtain the strain fields. From the performed test the influence of the experimental setup on the material response was evaluated. Obtained results showed that DIC method yields with lower measurement uncertainty since it takes into account the continuity of the displacement field. Experimental investigation on the proposed soft tissue reports higher stiffness in the fiber direction.

According to the obtained results for one measurement material parameters for three hyperelastic constitutive laws were determined. *Neo-Hooke*, *Mooney-Rivlin* and *Ogden* material models were taken into account. In order to find the most suitable model to describe the material behaviour two criteria were considered. First, the residuals between the experimental and identified data for the applied models was taken into account. The second point was to satisfy the Drucker stability criterion. *Ogden's* material model described as polynomial of the first order reports the best fit of the experimental data.

Key words: aorta, planar biaxial test, videoextensometer, digital image correlation, hyperelastic material model

1. UVOD

Brz razvoj tehnologije, tehnike, medicine i znanosti općenito, činitelji su modernog doba. U skladu s tim, postupno se nameće i novi, brži način života. Nametnuti ritam svakodneвно utječe na čovjeka, a posljedice se odražavaju na njegovo zdravlje. U stalnoj utrci s vremenom i neuravnoteženim načinom života povećava se vjerojatnost za pojavu bolesti. Najveći uzrok smrtnosti modernog doba su bolesti srca i krvnih žila (kardiovaskularne bolesti). Poznata je tvrdnja: „Stari smo koliko su stare naše krvne žile“. Ta stara izreka upozorava na iznimnu važnost očuvanja elastičnih i prohodnih krvnih žila. Na svjetskoj razini kardiovaskularne bolesti predstavljaju prioritetni zdravstveni problem. U svijetu od njih umre preko 16,5 milijuna ljudi godišnje, od kojih je više od 5 milijuna u Europi. Prema podacima Svjetske zdravstvene organizacije, one su prvi uzrok smrti u zapadnim zemljama, u više od 50% slučajeva. Hrvatska nije iznimka, gdje se oko 50% svih smrtnih slučajeva izravno povezuje s kardiovaskularnim bolestima. One su brojne i raznolike – od arterijske hipertenzije (visok tlak), srčanih aritmija, do srčanog i moždanog udara te zatajenja srca [1].

1.1. Motivacija

Zbog učestalosti kardiovaskularnih bolesti u svjetskoj populaciji, te s ciljem prevencije, ranog otkrivanja i poboljšanja u liječenju, provode se brojna biomehanička istraživanja. Za njihovu provedbu potrebno je povezivanje različitih disciplina, poput inženjerstva i medicine. U posljednje vrijeme mnogo se napora ulaže u području istraživanja računalnog modeliranja kardiovaskularnih zahvata. Da bi se izradili računalni modeli, potrebno je definirati konstitutivne materijalne modele za opisivanje mehaničkog ponašanja tkiva krvnih žila. Kako bi se tome približilo, teorijske osnove i eksperimentalna ispitivanja u razvoju konstitutivnih modela za ovo područje postala su predmet istraživanja mnogih autora. To ponajprije podrazumijeva eksperimentalna ispitivanja, dobivanje mehaničkih karakteristika i informacija o strukturi tkiva, što je prvi i najvažniji korak o kojem ovisi pouzdanost konstitutivnih, a u konačnici i numeričkih modela.

Za razliku od izotropnih, linearno–elastičnih materijala čije se mehaničke karakteristike ispituju jednoosnim (uniaksijalnim) testovima, biološka tkiva su najčešće anizotropna i nelinearno elastična. Njihovo složeno ponašanje nije lako predvidjeti, te jednoosna ispitivanja na takvim materijalima nisu dovoljna za potpuni uvid u ponašanje mekih tkiva.

Upravo iz tog razloga bilološki meki materijali se u novije vrijeme ispituju najmanje dvoosnim (biaksijalnim) testovima, što će biti opisano u ovome radu. Također, kvaliteta rezultata isključivo ovisi o metodi koja se primjenjuje za dobivanje pomaka i/ili deformacija ispitnog uzorka. U dosadašnjim istraživanjima najčešće se za mjerenje pomake koristio videoekstenzometar koji prati ponašanje materijala između dvije referentne točke (markera). Ta metoda je izuzetno dobra ako se mjerenje provodi na homogenom materijalu koji ima izotropna svojstva. Kao što je već spomenuto, za biološke materijale to nije slučaj. Zbog toga se rezultati dobiveni ovom metodom moraju uzeti s oprezom i potrebno ih je usporediti s drugim naprednijim metodama. U ovom radu, uz videoekstenzometar, za mjerenje pomaka korištena je i metoda korelacije digitalne slike. Ova optička metoda omogućuje praćenje cijelog polja pomaka kojom je moguće dobiti više informacija budući se mjerenje primjenjuje na više stupnjeva sloboda. Na taj način će uvid u odziv materijala omogućiti bolje opisivanje njegovog ponašanja. Usporedbom mjerenog cijelog polja pomaka/deformacija s numeričkim simulacijama moguće je procijeniti kvalitetu opisivanja ponašanja materijala primjenom različitih materijalnih modela. Time bi u budućnosti računalne simulacije mogle smanjiti broj potrebnih eksperimenata čime bi se smanjili troškovi i pojednostavila ispitivanja. No, za ostvarenje te ideje utrošit će se još puno vremena, truda i istraživanja. Danas su rezultati koji se dobivaju simulacijama samo približni, a validacija eksperimentom je nezaobilazan korak. Temeljni problem je nedostatak pouzdanih podataka o mehaničkom ponašanju bioloških materijala, poput krvnih žila. Često se kod pretkliničkih istraživanja krvnih žila koriste životinjski modeli koji svojim karakteristikama odgovaraju žilama kod čovjeka. Mehanička in vitro ispitivanja u sklopu ovog rada provedena su na svježim uzorcima aorte svinje u svrhu dobivanja mehaničkih podataka o ponašanju krvnih žila, točnije arterija.

1.2. Pregled dosadašnjih istraživanja

Povećanje broja oboljelih i umrlih od kardiovaskularnih bolesti potaknulo je brojna istraživanja na ovom području. Do danas ni jedna od tehnika liječenja, poput ugradnje prenosnica ili stentova ne uzima u obzir mehanička svojstva krvnih žila. Razlog tomu je već spomenuti nedostatak podataka o spregu mehaničkih i histoloških svojstava krvnih žila, koji koči implementaciju numeričkih modela i računalnih simulacija u stvarne medicinske probleme. Razvijeni su teoretski modeli s različitim namjenama i stupnjevima složenosti.

Međutim, takvi anizotropni, viskoelastični modeli nisu još primjenjeni u analizi medicinskih zahvata zbog izuzetne složenosti krvnih žila.

U tu svrhu koriste se samo izotropni, hiperelastični i linearno elastični numerički modeli temeljeni na metodi konačnih elemenata. Kao drugo ograničenje pouzdanijeg opisivanja ponašanja mekog tkiva, u ovom slučaju ljudskih arterija je nedostatak eksperimentalnih podataka.

To je posve novo područje koje se tek počelo istraživati u zadnjih desetak godina, i vrlo je malo radova objavljenih na tu temu. Prve podatke o ponašanju ljudskih koronarnih arterija pri jednoosnom vlačnom opterećenju predstavio je Yamada [2]. Zatim je Carmines [3] istražio vezu između unutarnjeg tlaka te aksijalnog i cirkularnog naprežanja za jednu ljudsku i jednu svinjsku koronarnu arteriju. U svrhu korištenja svinjskih arterija za biomehanička ispitivanja Van Andel [4] je u svojem istraživanju promatrao odziv ljudske i svinjske arterije pri napuhavanju. Dobiveni rezultati pokazali su da je svinjska arterija tri puta elastičnija od ljudske što se i očekivalo jer su uzorci ljudskih arterija uzeti iz pacijenata starije dobi kod kojih je bila prisutna ateroskleroza. U svrhu opisivanja ponašanja mekih tkiva korišteni su različiti anizotropni materijalni modeli [5]. Numeričkim simulacijama oponašalo se širenje ljudske ili jačne arterije. Iako su ti testovi na netaknutim arterijama ponudili vrijedne informacije o ponašanju arterija, one se nisu mogle jednostavno iskoristiti za definiranje konstitutivnog modela.

S ciljem određivanja anizotropnosti biloškog mekog tkiva Lally i dr. [6] provodili su jednoosne i dvoosne testove na svinjskim arterijama. U navedenom istraživanju uočena su odstupanja u rezultatima ovisno o vrsti svinje od koje uzorak potječe. Također su identificirani parametri hiperelastičnog materijalnog modela više polinomne forme (5 parametara materijala) kojima su dobivena dobra poklapanja s eksperimentalnim podacima. Lally i dr. [6] nazivaju ga Mooney–Rivlin, iako je to tehnički neispravno, budući da navedeni model sadrži samo dva parametra materijala. Provođenjem statičkih vlačnih ispitivanja na uzorcima ljudskih koronarnih arterija Claes i dr. [7] pridonijeli su boljem poznavanju mehaničkog ponašanja arterijskog tkiva.

Prvo kompleksnije ravninsko dvoosno eksperimentalno ispitivanje [8] koje je uzimalo u obzir utjecaja prekondicioniranja, temperature i mjesta s kojeg se uzorak uzima dalo je ključne rezultate koji definiraju današnju provedbu ispitivanja biloških mekih tkiva. Dokazan je pozitivan utjecaj prekondicioniranja kod jednoosnih i ravninskih vlačnih testova.

Naglašeno je kako se mehanička svojstva svinjske aorte mijenjaju s obzirom na mjesto s kojeg se uzima uzorak dok je temperaturni utjecaj na uzorak zanemariv.

Sommer i Holzapfel [9] provodili su vlačne testove s narinutim unutarnjim tlakom na ljudskim arterijama. U svom radu razvili su konstitutivni model i odredili 5 parametara materijala. Identificirani parametri materijala prilično dobro su opisivali odziv materijala dobiven iz eksperimentalnih rezultata za sve ispitne uzorke.

Kao što je poznato krvne žile sastoje se od četiri sloja. Schriebl i dr. [10] u svom su istraživanju proučavali mogućnosti odvajanja pojedinih slojeva tkiva ljudskih abdominalnih aorti. Iz jednoosnih ispitivanja pojedinih slojeva razvili su materijalni model uzimajući u obzir svojstva elastina i kolagena. Kao glavni doprinos ovog istraživanja je zaključak da uz intimu, mediu, adventitiju i elastin daje početnu krutost u elastičnim arterijama.

Provedbom ravninskih dvoosnih i troosnih posmičnih ispitivanja na uzorcima klijetke ljudskog srčanog mišića Sommer i dr. [11] pokušali su odrediti mehanička svojstva. Zaključili su da meko biološko tkivo (tj. klijetka srčanog mišića) karakterizira nelinearno, anizotropno i viskoelastično ponašanje. Uslijedilo je i istraživanje utjecaja posmičnih deformacija kod dvoosnog vlačnog ispitivanja ljudskog srčanog tkiva [14]. Mjerenje pomaka/deformacija laserskim ekstenzometrom pokazalo je prisutnost posmičnih deformacija kod ekvibiaksnog dvoosnog eksperimenta. Doprinos rada je u tome što su Sommer, Haspinger i dr. [14] ponudili unaprijeđenje ravninskih dvoosnih eksperimenata u svrhu smanjenja posmičnih naprezanja kada je na ispitni uzorak u oba smjera (okomita smjera) narinuto jednako opterećenje.

U navedenim istraživanjima (osim u [14]) u kojima su provedena eksperimentalna ispitivanja deformacije su mjerene ekstenzometrima. Njihova prednost je mjerenje pomaka/deformacija u uvjetima koji nisu standardni za inženjerske materijale (npr. uzorak je uronjen u fiziološku otopinu). Nedostatak korištene mjerne tehnike je što mjere lokalno ponašanje materijala između dvije točke [15]. Napredne optičke metode kao što je metoda korelacije digitalne slike (DIC) kao rezultat daje cijelo polje pomaka. Navedena metoda svoju je prvu primjenu doživjela početkom 80-ih godina dvadesetog stoljeća [16], a danas je jedna od uobičajenih metoda koje se koriste za dobivanje mehaničkih svojstava inženjerskih materijala. Područje u kojem ova metoda sve češće nalazi primjenu je biomehanika, odnosno počinje se aplicirati i na biološkim mekim tkivima [17].

U svom istraživanju Luyckx [18] primjenjuje spomenutu metodu za mjerenje 3D polja pomaka i deformacija na površini Ahilove tetive kod vlačnog in vitro ispitivanja. Rezultati ispitivanja potvrđuju da je DIC metoda vrlo precizna te primjenjiva na biološka tkiva. Moerman [19] pokazuje kako metoda korelacije digitalne slike u kombinaciji s metodom konačnih elemenata može predstavljati moćan alat za određivanje parametara neo-Hookeovog konstitutivnog zakona. Zhang [20], [21] je koristio DIC metodu za mjerenje velikih deformacija na površini uzoraka izrezanih iz aorte goveda. Uzorci su podvrgnuti uniaksijalnom vlačnom ispitivanju i izmjerene su deformacije i do 40 %. Arterijsko tkivo je kompozitni materijal koji se sastoji od elastina i kolagena i pokazuje izrazito nelinearan odziv prilikom velikih deformacija [21]. Primjenom navedenih metoda određen je i Poissonov faktor [22] na mekom tkivu.

1.3. Ciljevi i hipoteze istraživanja

Pregledom dosadašnjih istraživanja utvrđeno je da postoji relativno mali broj biaksijalnih eksperimenata na biološkim tkivima, a naročito krvnim žilama na kojima je primjenjena metoda korelacije digitalne slike. Štoviše, u istraživanjima koja su koristila metode mjerenja cijelog polja pomaka nisu istaknula mjernu nesigurnost i/ili standardnu rezoluciju mjerenih veličina. U ovom radu za analizu koristiti će se dvije optičke mjerne metode za određivanje ponašanja svinjske aorte uslijed ravninskog dvoosnog opterećenja. Za obje metode procijeniti će se mjerna nesigurnost. Pretpostavka je da će regularizirani DIC algoritam rezultirati pouzdanijim mjerenjima pomaka i deformacija budući da uzima u obzir kontinuirano polje pomaka.

Poznavanje biomehaničkih karakteristika stijenki krvnih žila vrlo je važno za točan opis konstitutivnih modela, te primjenu metode konačnih elemenata. Time će računalno modeliranje i simulacije omogućiti lakše predviđanje ishoda operacija. No, važno je napomenuti da računalne simulacije temeljene na numeričkim metodama daju približne rezultate koji odstupaju od stvarnih vrijednosti. Da bi one bile što točnije trebaju se validirati eksperimentalnim ispitivanjima. U radu su prikazani rezultati mehaničkih ispitivanja mekog tkiva (stijenki aorte) koje su podvrgnute ravninskom dvoosnom vlačnom opterećenju. Meka tkiva su pseudoelastični materijali, te se modeliraju najčešće kao hiperelastični, izotropni ili anizotropni. Iz tog razloga provode se multiaksijalna mehanička ispitivanja kako bi se odredila stvarna mehanička svojstva [8].

Ovaj rad obuhvaća analizu eksperimentalnih ispitivanja na četiri uzorka aorte mlade svinje te identificiranje parametara materijala za tri hiperelastična materijalna modela. Usporediti će se ponašanje materijala u aksijalnom i radijalnom smjeru vlakna. Iako svi uzorci pripadaju istoj aorti očukje se rasipanje rezultata budući da se radi o biloškom tkivu. Stoga će se procijeniti utjecaj odstupanja rezultata između uzoraka te s obzirom na orijentaciju vlakana. Usporedbom identificiranog i eksperimentalno određenog ponašanja materijala procijeniti će se konstitutivni zakon za koji je najbolje opisano dvoosno stanje naprezanja kod svinjske aorte.

1.4. Očekivani znanstveni doprinos

Kao biološko tkivo, krvne žile su nehomogeni materijal, anizotropnih svojstava, te su eksperimentalna ispitivanja na njima relativno novo područje. Zbog toga, svako takvo eksperimentalno ispitivanje je od posebnog značaja te pridonosi novim saznanjima.

U ovom radu bit će analizirana četiri ravninska dvoosna eksperimenta na uzorcima pripremljenim od svinjske aorte. Mjerenje pomaka i deformacija bit će provedena videoekstenzometrom i metodom korelacije digitalne slike (DIC). Metode mjerenja cijelog polja pomaka dosada nije primjenjena u korištenom eksperimentalnom postavu te se pretpostavlja dobivanje pouzdanijih rezultata.

Stoga je veliki doprinos savladavanje ispitnih uvjeta (uzorak je uronjen u fiziološku tekućinu) koja unose dodatno povećanje standardne rezolucije pomaka i deformacija. Kao validacija rezultata dobivenih DIC mjernom tehnikom koristiti će se podaci dobiveni videoekstenzometrom. Također će se provjeriti koja metoda daje rezultate s manjom standardnom rezolucijom pomaka/deformacija. Primjena DIC metode omogućit će dobivanje cijelog polja pomaka i deformacija na površini uzoraka čime će se doprinijeti boljem razumijevanju mehaničkog ponašanja tkiva na narinuto opterećenje. Za DIC analizu koristit će se regularizacijski RT3–DIC algoritam, u programskom paketu *Matlab*. Predloženi DIC algoritam je nova metoda koja još nije korištena u mehaničkoj analizi bioloških mekih tkiva. Prednost navedenog algoritma je u tome što filtrira sve fluktuacije koje nisu mehanički podatljive [24].

Prema dobivenim rezultatima pokušat će se pronaći hiperelastični materijalni model koji najpouzdanije opisuje eksperimentalne podatke. Navedeni model moći će se implementirati u programske pakete koji rade na principu metode konačnih elemenata te će se moći koristiti u numeričkim analizama.

1.5. Struktura rada

Rad je podijeljen u devet poglavlja. Prvo poglavlje je uvodni dio u kojem je iznesena motivacija, pregled dosadašnjih istraživanja, ciljevi i očekivani znanstveni doprinos ovog istraživanja.

U drugom poglavlju ukratko je opisan krvožilni sustav čovjeka – osnovni gradivni elementi (krvne žile), građa krvnih žila, fiziološka opterećenja u određenim dijelovima tijela (tlakovi) te najčešće bolesti.

Treće poglavlje odnosi se na usporedbu anatomije i mehaničkih karakteristika svinjskog i ljudskog krvožilnog tkiva u cilju dobivanja informacija o sličnostima i razlikama na koje treba obratiti pozornost.

U četvrtom poglavlju opisani su korišteni materijalni modeli. Navedeni su ulazni podaci potrebni za odabir materijalnog modela te hiperelastični odziv. Odabrani modeli koji se najčešće koriste u opisivanju ponašanja arterija: *neo – Hooke*, *Mooney – Rivlin* i *Ogden* su ukratko opisani. U svrhu određivanja parametara materijala predloženih konstitutivnih zakona objašnjen je termin kalibracije (tj. prilagodbe) materijalnih modela i naglašena važnost Druckerovog kriterija stabilnosti.

U petom poglavlju su detaljnije objašnjene mehaničke i optičke metode za mjerenje pomaka i/ili deformacija. U radu se za mjerenje pomaka i deformacija koristi videoekstenzometar i metoda korelacije digitalne slike (DIC), te su te dvije metode detaljnije objašnjene. Također, kako je za kalibraciju korišten programski paket *MCalibration*, prikazan je kratak postupak korištenja programom.

Šesto poglavlje odnosi se na parametarsku analizu rezolucije pomaka za DIC metodu, koja je provedena u cilju određivanja regularizacijskih parametara za dobivanje rezultata s najmanjom standardnom rezolucijom pomaka.

U sedmom poglavlju detaljno je opisano eksperimentalno ispitivanje uzoraka svinjske aorte. Najprije je opisan ravninski dvoosni test i priprema uzoraka, a nakon toga provedba ispitivanja, podešavanje i kalibracija sustava, mehaničko ispitivanje te određivanje mjerne nesigurnosti.

U osmom poglavlju prikazani su rezultati za uzorak AORTA1 i AORTA4. Rezultati su kritički promatrani, diskutirani i dan je osvrt na rezultate iz literature. Rezultati ostalih uzoraka dani su u prilogu.

Deveto poglavlje odnosi se na identifikaciju parametara materijala za tri odabrana hiperelastična materijalna modela. Prikazani su rezultati identifikacije za korištene konstitutivne zakone s pripadajućim standardnim greškama s obzirom na eksperimentalna ispitivanja.

U desetom poglavlju navedeni su globalni zaključci ovog rada.

2. KRVOŽILNI SUSTAV ČOVJEKA

Krvožilni (kardiovaskularni) sustav je sustav organa koji održavaju metabolizam u stanju homeostaze (zadovoljavanje tkivnih potreba). Funkcije krvožilnog sustava su prijenos tvari (hranjivih, otpadnih, hormona itd.), reguliranje tjelesne temperature i održavanje prikladne pH vrijednosti za optimalno preživljavanje i funkciju stanica. U najrazvijenijim zemljama svijeta, vodeći uzrok srčanog udara, moždanog udara i smrti su bolesti krvožilnog sustava, nastale višegodišnjim oštećivanjima [25].

Krvožilni sustav čovjeka dijeli se na veliki (sistemski) i mali (plućni) optok. Funkcionalni dijelovi krvožilnog sustava su krvne žile.

2.1. Krvne žile


Krvne žile su dio krvožilnog sustava čija je funkcija prenošenje krvi kroz tijelo. Dije se na arterijske i venske, određene prema tome kreće li se njihova krv prema ili od srca.

Postoje razne vrste krvnih žila:

- **Arterije** – dovode krv pod visokim tlakom u tkiva. Zbog toga imaju jake stijenke, a krv u njima protječe velikom brzinom. Najveća arterija naziva se aorta, nalazi se na izlazu iz srca, te odnosi krv bogatu kisikom. Aorta i njeni glavni ogranci čine takozvane elastične arterije. Te žile imaju velik lumen, ili šupljinu, što omogućava lak protok krvi. Osim toga, imaju i debele, mišićave stijenke protkane koncentrično poredanim slojevima elastina, proteina koji je rastezljiv poput gume. Time se ublažavaju posljedice naglog povećanja tlaka [26].
- **Arteriole** – krajnji mali ogranci arterijskog sustava. Djeluju poput kontrolnih ventila kroz koje se krv propušta u kapilare. Imaju snažnu mišićnu stijenku pomoću koje se mogu potpuno zatvoriti ili se njezinim opuštanjem mogu višestruko proširiti. Dakle, imaju sposobnost da znatno mijenjaju protok krvi kroz svako tkivo, ovisno o njegovim potrebama [27].
- **Kapilare** – najmanje krvne žile. Njihova funkcija je izmjena tekućine, hranjivih tvari, elektrolita, hormona i drugih tvari između krvi i međustanične tekućine. Da bi mogle obavljati tu ulogu, njihove stijenke su vrlo tanke i sadrže brojne kapilarne pore koje su propusne za vodu i tvari male molekularne mase [27].

- **Venule** – prikupljaju krv iz kapilara, te se postupno spajaju u sve veće vene [27]
- **Vene** – prenose krv iz venula natrag u srce. Uz to, one su glavni spremnik viška krvi. budući da je tlak u venskom sustavu vrlo nizak, venske su stijenke tanke, no ipak s dovoljno mišića koji omogućuju njihovo stezanje i širenje. Stoga vene djeluju kao spremnik manje ili veće količine krvi, čiji se volumen može nadzirati, ovisno o potrebama organizma [27]. Velike vene u kojima se skuplja krv su subklavialna vena, jugularna vena, bubrežna vena i vena ilijaka. Šuplje vene su dvije najveće vene koje dovode krv u srce [25].

Na slici 1. prikazana je raspodjela krvi u pojedinim dijelovima krvožilnog sustava.



Slika 1. Raspodjela krvi po dijelovima krvožilnog sustava[27]


2.2. Krvni tlak

Budući da srce neprekidno izbacuje krv u aortu, srednji je krvni tlak u aorti visok, prosječno oko 13 kPa. No srce izbacuje krv na mahove, pa arterijski tlak varira između 16 kPa (sistolički) i 10,5 kPa (dijastolički).

Dok krv teče kroz sistemski optok, srednji se tlak postupno snižava, sve do približno 0 kPa kad krv doprije do ušća šupljih vena na ulazu u srce. Tlak u sistemskim kapilarama varira između vrijednosti od 4,7 kPa na arterijskom kraju i 1,3 kPa na venskom kraju kapilara. Prosječni funkcionalni kapilarni tlak u većini vaskularnih područja iznosi oko 2,3 kPa, a to je dovoljno nizak tlak da vrlo malo plazme istječe kroz sitne otvore u kapilarnim stijenkama, iako kroz te iste otvore hranjive tvari mogu lako difundirati do stanica u blizini kapilara.

Kao i u aorti, i u plućnim arterijama krv teče na mahove, no vrijednosti tlakova mnogo su niže [27].


Na slici 2. prikazani su normalni krvni tlakovi u pojedinim dijelovima krvožilnog sustava.



Slika 2. Normalni krvni tlakovi u pojedinim dijelovima krvožilnog sustava [27]

2.3. Građa krvnih žila

Sve krvne žile u osnovi imaju istu građu. Iznutra su presvučene endotelijem (tunica intima) koji je okružen subtelijem, veznim tkivom. Oko njega nalazi se sloj vaskularnog glatkog mišićnog tkiva (tunica media), koje je visoko razvijeno kod arterija. Na kraju se nalazi sloj tkiva poznat kao tunica adventitia koji sadrži živce koji opskrbljuju mišićni sloj, kao i kapilare u većim krvnim žilama. Kapilare su građene od sloja endotelija i rijetkog vezivnog tkiva. Na slici 3. prikazana je građa arterija i vena. Osnovna razlika je u volumenu lumena (prostor unutar žile kroz koji protječe krv), te količini glatkog mišićnog tkiva. Uz to, vene još sadrže i nepovratne ventile tzv. zaliske koje onemogućuju povrat krvi (jer je u venama puno manji tlak nego u arterijama).



Slika 3. Građa krvnih žila [28]

Po građi su stijenke arterija mnogo jače nego stijenke vena. Zbog toga su arterije prosječno oko 8 puta manje rastezljive od vena. Drugim riječima, uz jednako povišenje tlaka, vena može primiti 8 puta veću količinu dodatne krvi nego arterija slične veličine [27].

2.4. Bolesti krvožilnog sustava

Arterioskleroza, ili “ovapnjenje arterija”, u mnogim je zemljama jedan od glavnih uzroka smrti. Njen najčešći oblik, ateroskleroza, nastaje zbog nakupljanja masnih naslaga koje nalikuju kašastoj masi (aterom) u unutrašnjosti arterija. Te naslage smanjuju arterijski lumen, ili šupljinu, i stoga lako može doći do potpunog začepljenja i prsnuća arterije kad nakupljanje plaka dođe u kritični stadij. Potpuno začepljenje mogu uzrokovati i krvni ugrušci koji putuju žilama te grčevi mišića arterijskih stijenki.

Naročito je opasno nakupljanje plaka na stijenkama koronarnih arterija, koje opskrbljuju krvlju srčani mišić. Stoga srčani mišić ne dobiva dovoljno krvi, što ima za posljedicu anginu pectoris — tupu bol i pritisak u prsnom košu, koji se često javljaju kod fizičkog naprezanja. Ako se koronarna arterija potpuno začepi, to može dovesti do srčanog udara i oštećenja srčanog mišića. Težak srčani udar može uzrokovati potpuni prestanak rada srca.

U rizične faktore koji doprinose aterosklerozi ubrajaju se pušenje, emocionalni stres, dijabetes, gojaznost, nedovoljna fizička aktivnost, visoki krvni tlak, ishrana s puno masti i genetsko nasljeđe [26].

3. ŽIVOTINJSKI MODELI ZA PRETKLINIČKA ISTRAŽIVANJA

U zadnjih 20-ak godina bilježi se značajan napredak u liječenju kardiovaskularnih bolesti. Kako bi se ubrzali procesi liječenja i očuvalo zdravlje ljudi, znanstvena otkrića i nove tehnologije moraju postati dio praktične primjene. Da bi se uopće došlo do nekog otkrića, počinje se od osnovnih istraživanja koja se potom primjenjuju na kliničkoj razini. Nezaobilazan korak u istraživanjima novih tehnologija su pretklinička ispitivanja na životinjskim modelima. Iako se ni jednim životinjskim modelom ne može u potpunosti kopirati složenost ljudskih patoloških stanja, oni su ključan element u istraživanjima mehanizama bolesti te testiranjima dijagnostičkih i interventnih tehnologija. Do značajnih otkrića u području kardiovaskularne biologije na staničnoj i molekularnoj razini došlo se zahvaljujući malim životinjskim modelima, naročito miševima. Iako u usporedbi miša i čovjeka postoje značajne razlike s obzirom na kardiovaskularne karakteristike, svejedno je to otkriće bilo velik iskorak u daljnjim istraživanjima.

Da bi se otkrića na mišjim modelima mogla primjeniti u terapijske i interventne svrhe na ljudima, ključna su ispitivanja na velikim životinjskim modelima koji približno opisuju čovjekovu fiziologiju i anatomiju.

U pretkliničkim istraživanjima kao životinjski model se često uzima domaća svinja. U usporedbi s ostalim životinjskim vrstama, svinja ima određene fiziološke i anatomske značajke koje su vrlo slične ljudskoj fiziologiji i anatomiji. Zbog toga su za neka istraživanja svinjska tkiva najbolji izbor. Sustavi koji se najčešće navode kao prikladni uključuju krvožilni, mokraćni, pokrovni i probavni sustav. Ta saznanja su u posljednjih 20 godina rezultirala upotrebom svinje kao glavne životinjske vrste za pretklinička istraživanja.

U sljedećem potpoglavlju će se opisati sličnosti i razlike između svinjskog i ljudskog krvožilnog sustava.

3.1. Usporedba anatomije svinjskog i ljudskog krvožilnog tkiva

Fiziologija i anatomija svinjskog srca je tipična kao i kod većine sisavaca, uz tek nekoliko varijacija. Sustav opskrbe srca sustavom koronarnih arterija je gotovo identičan onom kod čovjeka. Uz to, dimenzije srca i krvnih žila kod odraslih Hanfordskih mini- svinja su više analogne čovjekovim, nego onim kod pasa ili čovjekolikih majmuna. Naravno postoje i određene razlike.

Glavna razlika u anatomiji u usporedbi s ostalim sisavcima je poluneparna vena¹, koja ulazi u koronarni sinus². Kod ostalih sisavaca, spomenuta vena ulazi u gornju šuplju venu³. Također, svinje nemaju kolateralnu krvnu mrežu⁴, te u slučaju okluzije (začepljenja krvne žile) odmah dolazi do srčanog udara. Nije jednak ni raspored živčanih vlakana endokarda⁵ i epikarda⁶, koji se kod svinja aktiviraju istovremeno. Unatoč navedenim razlikama, svinja se vrlo uspješno koristi u istraživanjima provedbenog srčanog mišićja.

Razlike postoje i između pojedinih pasmina svinja, pa i unutar iste pasmine, ali različitih dobnih skupina.

Na primjer, otkucaji srca kod mladih svinja mnogo su viši nego kod starijih. Kod odrasle svinje masa srca je otprilike 0,5% od ukupne mase. Taj postotak se s godinama smanjuje, te padne na otprilike 0,3% kod životinja starije dobi. Kod čovjeka je vrlo slično. Danas se svinja koristi kao „model za uzgajanje srca“ koje će se koristiti za neke kirurške zahvate. Rast srca i krvožilnog sustava svinje od rođenja do 4 mjeseca starosti je analogno rastu istog sustava kod tinejdžera. Sustav opskrbe krvlju koronarnih arterija i provedbenog srčanog mišićja⁷ pripada desno dominantnom⁸, kao i kod 90% ljudske populacije. U perifernim venama imaju zaliske, kao i ljudi [29]. U literaturi je dostupno još nebrojeno puno informacija o biološkim sličnostima i razlikama ljudskog i svinjskog tkiva, no kako to nije tema ovog rada, više će se pozornosti usmjeriti na mehaničke karakteristike stijenki krvnih žila, točnije arterija.

3.2. Usporedba mehaničkih karakteristika svinjskog i ljudskog krvožilnog tkiva

Za provedbu istraživanja na arterijama često se kao testna životinja koristi svinja. U nastavku će se pokazati usporedba mehaničkih karakteristika svinjskih i ljudskih arterija [30]. Za eksperiment su korištene koronarne i unutarnje prsne arterije mladih svinja i ljudi starije dobi.

¹ Vena koja odvodi deoksigeniranu (siromašnu kisikom) krv iz lijeve strane stražnjeg dijela trupa.

² Vena koja dovodi krvi iz tijela srca (nakon opskrbe srčanog mišića).

³ Vena koji dovodi deoksigeniranu krv iz gornje polovice tijela u desnu pretkljetku srca.

⁴ Mreža tankih krvnih žila koja u normalnim uvjetima nije otvorena. Kada se arterije suze do točke kada je protok krvi kroz određeno tkivo ograničen, kolateralna cirkulacija može se povećati i postati aktivna. To omogućuje protok krvi oko blokirane (sužene) arterije do obližnje arterije ili do iste arterije ispod mjesta suženja, štiteći tkivo od oštećenja.

⁵ Unutarnji sloj srčanog mišića.

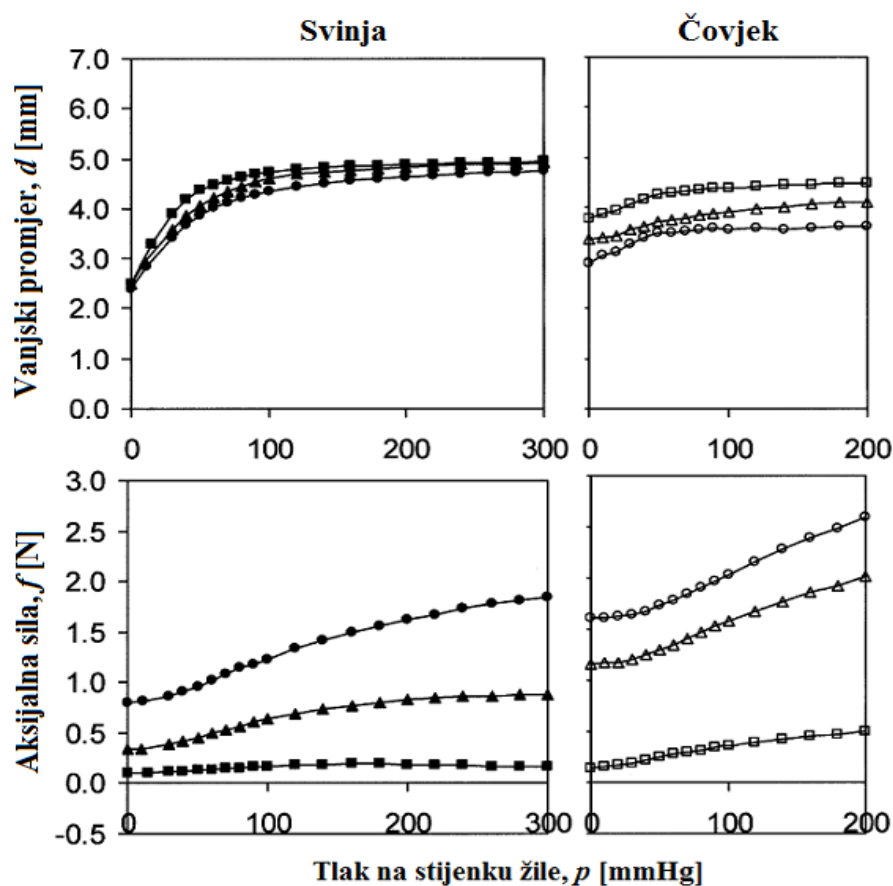
⁶ Vanjski sloj srčanog mišića.

⁷ Stanice srčanog mišića koje imaju sposobnost stvaranja impulsa, što uzrokuje kontrakciju srčanog mišića (SA i AV čvor).

⁸ Desna koronarna arterija spušta se uz stražnji zid srca i naziva se zadnja silazna arterija. Kod nekih ljudi zadnja silazna arterija nastaje iz lijeve koronarne arterije, što nije čest slučaj.

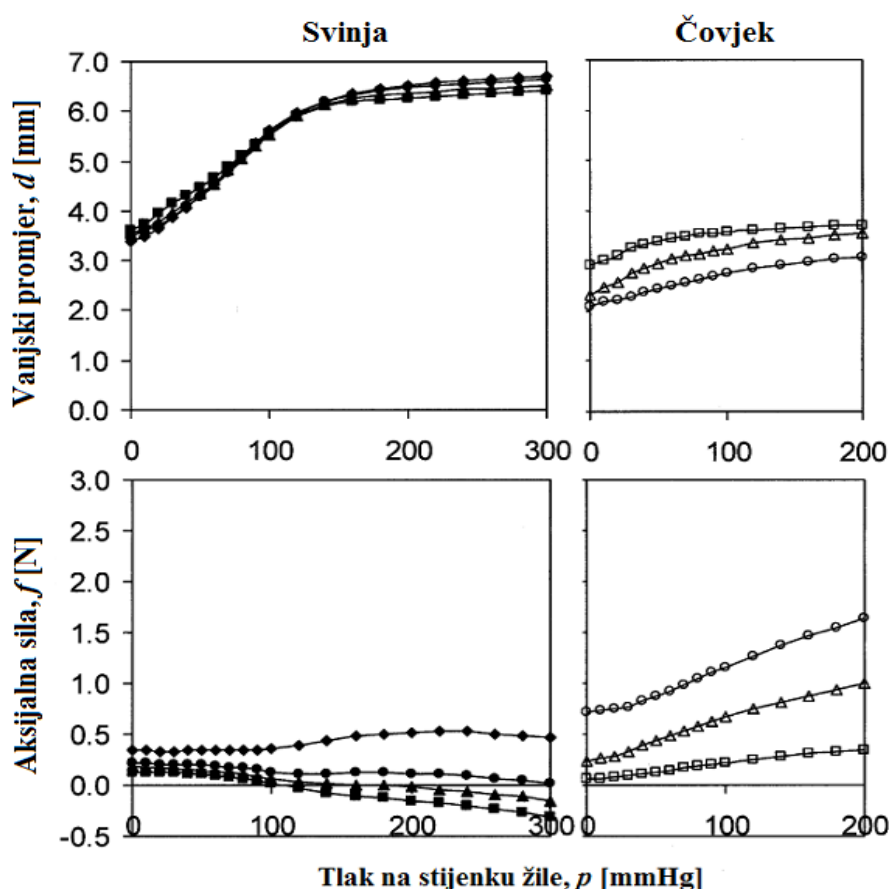
Uzorci arterija uzeti su od 10 ljudi (u rasponu 61-85 godina) i 14 svinja (u rasponu $78,7 \pm 5,8$ kg). Čuvani su u fiziološkoj otopini na 4°C , te ispitani u roku 24 sata od pripreme. Provedeno je nestandardno statičko vlačno ispitivanje na kidalici u posebnim uvjetima. Svaki uzorak je predopterećen aksijalnom vlačnom silom, i unutar svake žile je narinut tlak (tako da se simulira prirodno opterećenje). Na uzorcima su laserski mjerene promjene dimenzija te dobiveni odnosi: tlak – promjer, tlak – aksijalna sila, aksijalno naprezanje – deformacija, te cirkularno naprezanje – deformacija. Više detalja o pripremi i provedbi eksperimenta nalazi se u literaturi [30]. Odgovor na pitanje da li mehanička svojstva svinjskih arterija dovoljno dobro odgovaraju mehaničkim svojstvima ljudskih arterija, slijedi u prikazu rezultata.

Zbog jasnoće je odabran po jedan reprezentativni uzorak od svake arterije, kako bi se pokazali ti odnosi za cijelu skupinu uzoraka. Slika 4. prikazuje usporedbu dijagrama ovisnosti vanjskog promjera žile (koronarne arterije) i aksijalne sile o tlaku na stijenku žile kod svinje i čovjeka. Svaki uzorak podvrgnut je ispitivanju tri puta, različitim vrijednostima sile aksijalnog predopterećenja (najprije manjim, zatim većim).



Slika 4. Dijagrami ovisnosti vanjskog promjera žile i aksijalne sile o tlaku na stijenku žile (koronarne arterije) [29]

Iz dijagrama je vidljivo da se u rasponu tlaka 0-100 mm/Hg koronarna arterija svinje proširila više od ljudske. Slika 5. prikazuje usporedbu dijagrama ovisnosti vanjskog promjera žile (prsne arterije) i aksijalne sile o tlaku na stijenku žile kod svinje i čovjeka.

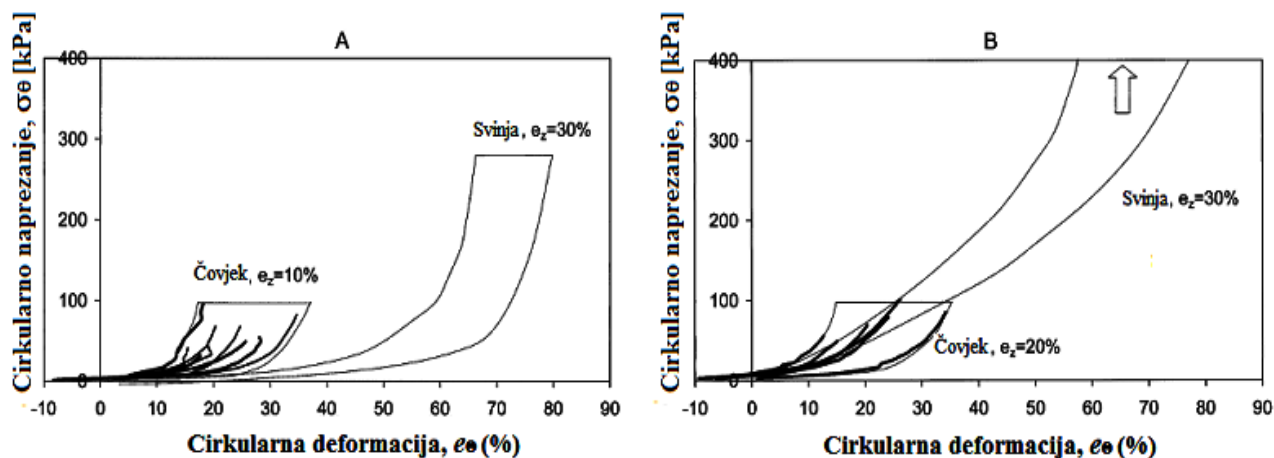


Slika 5. Dijagrami ovisnosti vanjskog promjera žile i aksijalne sile o tlaku na stijenu žile (prsne arterije) [29]


Slično kao i kod koronarne arterije, na dijagramu se vidi da se promjer prsne arterije kod svinje puno više povećao u usporedbi s ljudskom. Isto tako, ovaj oblik krivulje u blagom obliku slova S je tipičan opis za elastične arterije, koji se teško može uočiti kod uzoraka ljudskih arterija. Kod prsne arterije svinje, aksijalna sila opada povećanjem tlaka u svim rasponima predopterećenja, dok se kod ljudske samo povećava.

Na temelju dobivenih podataka provedeni su izračuni naprezanja i deformacija [30], te dijagramima u nastavku pokazani njihovi odnosi. Dobiveni rezultati upućuju na znatne razlike u odnosu naprezanja i deformacija. Kao posljedica toga, dijagrami su prikazani u obliku zatvorenih površina („envelopa“) unutar kojih se nalaze krivulje odnosa naprezanje – deformacija za svaku vrijednost predopterećenja svih uzoraka. Na slici 6. prikazana je usporedba odnosa cirkularnog naprezanja u ovisnosti o cirkularnoj deformaciji ljudskih i svinjskih koronarnih arterija (A) i prsnih arterija (B).

Na slici 7. prikazana je usporedba odnosa aksijalnog naprezanja u ovisnosti o cirkularnoj deformaciji ljudskih i svinjskih koronarnih arterija (C) i prsnih arterija (D).



Slika 6. Usporedba odnosa cirkularnog naprezanja u ovisnosti o cirkularnoj deformaciji za ljudske i svinjske arterije [29]



Slika 7. Usporedba odnosa aksijalnog naprezanja u ovisnosti o cirkularnoj deformaciji za ljudske i svinjske arterije [29]

Najupečatljiviji podatak je cirkularna deformacija svinjskih arterija koja je oko tri puta veća nego kod ljudskih arterija. Aksijalna i cirkularna naprezanja koronarnih arterija svinje su manja od istih naprezanja u koronarnim arterijama čovjeka pri istoj cirkularnoj deformaciji.

Za danu deformaciju modul elastičnosti je manji kod svih svinjskih arterija. To upućuje na činjenicu da su stijenke svinjskih arterija mnogo više elastične od onih kod ljudi.

Može se zaključiti da su dimenzije svinjskih i ljudskih arterija generalno slične, jedino je debljina stijenke unutarnje prsne arterije kod svinje nešto manja. Također, kod svinja je stijenka unutarnje prsne arterije pokazala manju elastičnost od stijenke koronarne arterije, dok su kod ljudi obje arterije pokazale jednaku elastičnost. Sveukupno, svinjske arterije su u cirkularnom i aksijalnom smjeru mnogo više elastične u usporedbi s ljudskim arterijama. U skladu s time, svinjske arterije se mogu sigurno rastegnute do 60% (čak i 70%), dok ljudske tek 20% prije dostizanja maksimalne cirkularne deformacije. No to može biti posljedica razlike u starosti uzoraka, jer je poznato da s godinama žile gube elastičnost. Također, pojava ateroskleroze ima velik utjecaj na svojstva stijenki žila [29].

4. MATERIJALNI MODELI

4.1. Odabir konstitutivnog materijalnog modela

Izbor odgovarajućeg konstitutivnog materijalnog modela nije jednostavan zadatak. Najprije je potrebno klasificirati ispitni materijal, prema poznatom sastavu i dobivenom mehaničkom odazivu pri željenim uvjetima opterećenja. Potrebno je definirati svojstva materijala npr.: izotropan/anizotropan, homogen/heterogen, definirati osnovno mehaničko ponašanje npr.: elastično/neelastično, linearno/ nelinearno itd. Za elastično ponašanje vrijedi:

1. pravci opterećenja i rasterećenja se poklapaju,
2. materijal trenutačno reagira na nametnuto opterećenje i nije ovisno o vremenu,
3. materijal se vraća u početno stanje nakon rasterećenja.

Drugim riječima, kod elastičnog ponašanja nema rasipanja. Važno je naglasiti da je elastičnost ponašanje, i da ne postoji (stvarni) elastičan materijal jer se ni jedan materijal ne ponaša elastično u svim uvjetima. Također, ako se elastično ponašanje kvantificira u uvjetima energije deformacije W , to je obnovljiva energija pohranjena u materijalu tijekom deformiranja, tada se to ponašanje naziva hiperelastičnost (*Green*-ova elastičnost). Kada ponašanje nije elastično, kaže se da je neelastično, a razlikuju se viskoelastično i plastično ponašanje. Viskoelastičnost je kombinirano svojstvo viskoznog (karakteristično za tekućine) i elastičnog (karakteristično za čvrste tvari) ponašanja. Viskoelastično ponašanje karakteristično je za materijale koji se sastoje od krutih i tekućih konstituenata, a najbolji primjer su vlažna tkiva. Viskoelastičnost karakterizira pužanje, relaksacija i histereza. Pužanje je deformiranje ovisno o vremenu pod utjecajem konstantnog opterećenja. Relaksacija je vremenski ovisno smanjenje sile (odnosno naprezanja) za konstantnu deformaciju. Histereza se očituje u nepoklapajućim krivuljama opterećenja i rasterećenja. Nije sva energija deformacije sadržana u materijalu obnovljiva [31]. Plastičnost karakterizira pojava trajne (plastične) deformacije u materijalu pod djelovanjem dovoljno velike sile.

Analiza viskoelastičnog ponašanja vrlo je složena i često se koriste određena pojednostavljenja. Iz tog razloga u literaturi se za opisivanje ponašanja bioloških mekih tkiva često primjenjuju hiperelastični modeli. Danas ih ima mnogo, jednostavni su za korištenje i implementirani su u programske pakete koji rade na principu metode konačnih elemenata (*Abaqus*, *ANSYS*, *ADINA* i dr.). Iz tih razloga za opisivanje ponašanja ispitivanog mekog tkiva u ovom radu su korišteni hiperelastični materijalni modeli.

4.2. Hiperelastični materijalni modeli

Hiperelastičnost je teorija nelinearno – elastičnih materijala koja se često primjenjuje za opisivanje ponašanja elastomera, gume i drugih mekih, fleksibilnih materijala koje karakterizira pojava velikih deformacija pri opterećenju. Popularna je jer se lako koristi u metodi konačnih elemenata (MKE) i jer je dostupna kao opcija u svim programskim paketima koji rade na principu MKE [32]. Prve hiperelastične modele razvili su *Ronald Rivlin* i *Melvin Mooney*. Nazivaju se *neo-Hooke* i *Mooney-Rivlin* modeli. Od tada su razvijeni mnogi drugi hiperelastični modeli. Od ostalih modela u širokoj primjeni mogu se izdvojiti *Ogden* i *Arruda Boyce* [33].

Glavno obilježje hiperelastičnih materijala je postojanje energije deformacije (eng. *strain energy*)

$W = \rho_0 \psi$ koja se može izraziti kao funkcija tenzora deformiranosti odnosno kao funkcija tenzora deformacije. Funkcija W je elastični potencijal i predstavlja raspodjelu energije deformacije po jedinici obujma, ρ_0 je gustoća nedeformiranog tijela, a ψ izražava raspodjelu energije deformacije po masi i naziva se Helmholtzova slobodna energija (eng. *Helmholtz free energy*). Pošto se elastično ponašanje materijala određuje iz elastičnog potencijala sustav je konzervativan u nekom zatvorenom ciklusu. Derivacijom elastičnog potencijala po vremenu dobiva se snaga naprezanja (eng. *stress power*)

$$w = \dot{W} = \frac{dW}{dt} = \rho_0 \dot{\epsilon} = \mathbf{S} : \dot{\mathbf{E}}, \quad (1)$$

za slučaj kada je $W = W(\mathbf{E})$, gdje je \mathbf{E} *Green–Lagrangeov tenzor deformacije*. Prema lančanom pravilu derivacija W po vremenu glasi

$$\frac{dW}{dt} = \frac{\partial W}{\partial \mathbf{E}} \frac{\partial \mathbf{E}}{\partial t}. \quad (2)$$

Iz jednadžbe (1) slijedi izraz za tenzor naprezanja (u ovom slučaju drugi *Piola – Kirchhoffov tenzor naprezanja* [34]):

$$\mathbf{S} = \frac{\partial W(\mathbf{E})}{\partial \mathbf{E}}. \quad (3)$$

4.2.1. Vrste hiperelastičnih modela

Većina programskih paketa baziranih na MKE ima ugrađen velik izbor različitih hiperelastičnih modela. Popis najčešće dostupnih izotropnih hiperelastičnih modela:

- *Neo-Hooke*,
- *Mooney-Rivlin*,
- *Ogden*,
- *Yeoh*,
- *Arruda-Boyce* ,
- *Polynomial*,
- *Van Der Waals*,
- *Marlow* (u *Abaqus-u*), *Response Function* (u *ANSYS-u*),
Sussman-Bathe (u *ADINA-i*),
- *Extended Tube Model*,
- *Gent*,


dok su najčešći dostupni anizotropni hiperelastični modeli

- *Holzapfel-Gasser-Ogden*,
- *Fung*,
- *Bischoff anisotropic eight-chain*,
- *Bergstrom anisotropic eight-chain* [32].

Identificiranje parametara materijala pokazat će se za tri hiperelastična materijalna modela: *neo-Hooke*, *Mooney-Rivlin* i *Ogden*.

Ako je $J = \det(\mathbf{F}) = 1$, deformiranje je izohorno, tj. takvo da obujam svakog elementa ostaje nepromijenjen (uvjet koji vrijedi za nestlačive materijale) [35]. U ovom radu pretpostavka je da je tkivo nestlačivo, te vrijede gore navedeni izrazi.

Parametri materijala za navedene hiperelastične modele mogu se razmatrati za tri stanja: jednoosno, dvoosno i ravninsko stanje deformacija (slika 8.).



Slika 8. Statički pokus: a) jednoosni, b) dvoosni, c) ravninsko stanje deformacija [39]

Pripadajući gradijenti deformiranja \mathbf{F} za ova tri slučaja su redom

$$\mathbf{F} = \begin{pmatrix} \lambda & 0 & 0 \\ 0 & \frac{1}{\sqrt{\lambda}} & 0 \\ 0 & 0 & \frac{1}{\sqrt{\lambda}} \end{pmatrix}, \quad \mathbf{F} = \begin{pmatrix} \lambda & 0 & 0 \\ 0 & \lambda & 0 \\ 0 & 0 & \frac{1}{\lambda^2} \end{pmatrix}, \quad \mathbf{F} = \begin{pmatrix} \lambda & 0 & 0 \\ 0 & \frac{1}{\lambda} & 0 \\ 0 & 0 & 1 \end{pmatrix}. \quad (4)$$

Invarijante za slučaj jednoosnog stanja naprezanja (a) glase

$$I_1 = \lambda_1^2 + \lambda_2^2 + \lambda_3^2 = \lambda^2 + \frac{2}{\lambda}, \quad I_2 = \lambda_1^2 \lambda_2^2 + \lambda_2^2 \lambda_3^2 + \lambda_3^2 \lambda_1^2 = 2\lambda + \frac{1}{\lambda^2}, \quad (5)$$

analogno (5), invarijante za slučaj dvoosnog stanja naprezanja (b) su definirane izrazima

$$I_1 = 2\lambda^2 + \frac{1}{\lambda^4}, \quad I_2 = \lambda^4 + \frac{2}{\lambda^2}, \quad (6)$$

a za invarijante za slučaj ravninskog stanja deformacija (c) vrijedi

$$I_1 = 1 + \lambda^2 + \frac{1}{\lambda^2}, \quad I_2 = I_1 = 1 + \lambda^2 + \frac{1}{\lambda^2}. \quad (7)$$

4.2.1.1. Materijalni model Neo-Hooke

Neo-Hooke je hiperelastični materijalni model, sličan *Hookevom* zakonu, koji se može koristiti za predviđanje nelinearnog ponašanja (odnos naprezanje – deformacija) materijala podvrgnutog velikim deformacijama. Model je 1948. predložio *Ronald Rivlin*. U usporedbi s linearno elastičnim materijalima, krivulja naprezanje – deformacija kod *neo-Hookeova* materijalnog modela nije linearna. Model ne uzima u obzir rasipanje energije poput topline prilikom deformiranja i pretpostavlja se savršena elastičnost u svih fazama deformiranja. *Neo-Hookeov* model ne predviđa porast modula elastičnosti kod velikih deformacija i točan je za deformacije manje od 20%. Model je također neadekvatan za biaksijalna stanja naprezanja u tom slučaju zamjenjuje se *Mooney-Rivlinovim* modelom.

Energija deformiranja za *neo-Hookeov* materijalni model (za nestlačive materijale) glasi

$$W = C_{10}(I_1 - 3), \quad (8)$$

gdje je C_{10} parametar materijala [36].

4.2.1.2. Materijalni model Mooney-Rivlin

U mehanici kontinuuma, *Mooney-Rivlin* je hiperelastični materijalni model kod kojeg je energija deformiranja W linearna kombinacija dviju invarijanti lijevog *Cauchy – Greenovog* tenzora deformiranosti \mathbf{B} . Model je 1940. predložio *Melvin Mooney*, a 1948. ga je *Ronald Rivlin* izrazio u ovisnosti o invarijantama.

Energija deformiranja *Mooney-Rivlinova* materijalnog modela (za nestlačive materijale) dana je izrazom

$$W = C_{10}(I_1 - 3) + C_{01}(I_2 - 3), \quad (9)$$

gdje su C_{10} i C_{01} parametri materijala.

4.2.1.3. Materijalni model Ogden

Ogden je hiperelastični materijalni model koji se koristi za opisivanje složenog nelinearnog ponašanja materijala poput gume, polimera i biološkog tkiva. Model je 1972. razvio *Ray W. Ogden*.

Energija deformiranja *Ogdenova* materijalnog modela (za nestlačive materijale) definirana je izrazom

$$W(\lambda_1, \lambda_2) = \sum_{p=1}^N \frac{\mu_p}{\alpha_p} (\lambda_1^{\alpha_p} + \lambda_2^{\alpha_p} + \lambda_1^{-\alpha_p} \lambda_2^{-\alpha_p} - 3), \quad (10)$$

gdje su μ_p i α_p parametri materijala [38].

4.2.2. Kalibracija hiperelastičnih modela

Kako bi se dobiveni eksperimentalni podaci i ponašanje ispitivanog materijala moglo primijeniti u numeričkim analizama potrebno je provesti kalibraciju (prilagodbu) odabranog materijalnog modela prema učitanim eksperimentalnim podacima.

Programski paket *Abaqus* ima mogućnost kalibracije krivulja prema traženom materijalnom modelu ili eksperimentalnim podacima, a minimalna vrijednost potrebnog broja točaka je dvije. Prilagodba krivulja rješava se uz kriterij greške E_{num} prema metodi najmanjih kvadrata (eng. *least – squares fit*) izrazom

$$E_{\text{num}} = \sum_{i=1}^n (1 - T_i^{\text{th}} / T_i^{\text{test}})^2, \quad (11)$$

Indeks „th“ označava teoretsku (eng. *theoretical*) vrijednost prema odabranom materijalnom modelu, dok indeks „test“ označava parametre eksperimentalno mjerenih podataka koji su ubačeni u *Abaqus* [39]. Mogućnost kalibracije nude i drugi programski paketi temeljeni na MKE (*ANSYS*, *ADINA*). Daljnjim pretraživanjem literature pronađeno je još nekoliko komercijalno dostupnih programskih paketa koji su dizajnirani isključivo u svrhu kalibriranja materijalnih modela (*Hyperfit*, *MCalibration*). U praksi, oni su se pokazali kvalitetnijim i preciznijim (naročito kod prilagodbe složnijih materijalnih modela kao npr. *Ogden*, *Arruda – Boyce* i dr.) u odnosu na mogućnosti navedenih paketa temeljenih na MKE, što je i logično.

Programski paketi *Hyperfit* [40] i *Mcalibration* [41] komercijalno su dostupni u besplatnoj verziji uz ograničene mogućnosti.

Međutim, začetnik programskog paketa *MCalibration* (*Jorgen Bergstrom*) omogućio je privremenu licencu za upotrebu standardne verzije programa [42]. Uz tu mogućnost identificiranje parametara materijala u svrhu ovog rada napravljeno je uz pomoć programskog paketa *MCalibration*, v.3.1.0. Postupak kalibracije naveden je u sljedećem poglavlju, a rezultati kalibracije za odabrane konstitutivne modele su prikazani u devetom poglavlju.

Kalibracija (prilagodba) krivulja u ovom programskom paketu može se riješavati pomoću tri dostupne funkcije prilagodbe (eng. *fitness function*) [43]. To su

1. *NMAD* (eng. *normalized mean absolute difference*) definiranu prema

$$NMAD = 100 \frac{\langle |\sigma^p - \sigma^e| \rangle}{\langle |\sigma^e| \rangle}. \quad (12)$$

2. *MSD* (eng. *mean square difference*) definiranu prema

$$MSD = 100 \langle |\sigma^p - \sigma^e|^2 \rangle. \quad (13)$$

3. *R2* (eng. *coefficient of determination*) definiranu prema

$$R2 = 100(1 - R^2), \quad (14)$$

pri čemu je

$$R^2 = 1 - \frac{\sum_{i=1}^n (\sigma_i^p - \sigma_i^e)^2}{\sum_{i=1}^n (\sigma_i^e - \langle \sigma^e \rangle)^2}, \quad (15)$$

gdje je σ^p predviđeno naprezanje, a σ^e je eksperimentalno naprezanje (ili deformacija ako je uključena opcija *stress control*). U ovom slučaju korišten je koeficijent kalibracije *R2* jer ga program može prikazati. On pokazuje koliko dobro krivulja materijalnog modela prati eksperimentalne podatke. Isprobane su i ostale funkcije, no za korištene modele dobiveni su jednaki rezultati.

Također, vrlo je važno napomenuti da za ispravnu validaciju odabranog hiperelastičnog modela nije dovoljno samo dobro opisivanje dobivenih eksperimentalnih rezultata. Ključan korak je provjera *Druckerovog kriterija stabilnosti*.

4.2.3. *Druckerov kriterij stabilnosti*

Druckerov kriterij stabilnosti (predložio *Rodney Hill*, pa se naziva i *Hill-ov kriterij stabilnosti*) odnosi se na skup matematičkih kriterija koji ograničavaju moguće odnose naprezanja i deformacije koje neki materijalni model može zadovoljiti. Postulati su imenovani po *Danielu C. Druckeru*. Materijalni model koji ne zadovoljava ove kriterije smatra se nestabilnim u smislu da primjena opterećenja u nekoj materijalnoj točki može dovesti do proizvoljne deformacije koja je nelogična i potpuno netočna. Na *Druckerov kriterij stabilnosti* često se poziva u nelinearnoj analizi metodom konačnih elemenata.

Materijali koji zadovoljavaju ove kriterije su uglavnom dobro prilagođeni za numeričku analizu, dok materijali koji ne zadovoljavaju ovaj kriterij će vjerojatno uzrokovati poteškoće (pojava nejedinstvenosti (divergencije) ili singulariteta) tijekom analiza [44]. Drugim riječima, materijal koji zadovoljava *Druckerov kriterij stabilnosti* mora prikazati realno moguć način deformacije. Takav materijal smatra se stabilnim i prihvatljivim za primjenu u numeričkim analizama. *Druckerov kriterij stabilnosti* je strogi uvjet vezan na prirast unutarnje energije materijala koji nalaže da se ona može samo povećati. Drugim riječima, uvjet nalaže pozitivnu promjenu energije u zatvorenom ciklusu.

Za izotropne, nestlačive materijale, *Druckerov kriterij* može se izraziti u obliku:

$$d\boldsymbol{\sigma} : d\boldsymbol{\varepsilon} \geq 0, \quad (16)$$

gdje $d\boldsymbol{\sigma}$ predstavlja prirast tenzora naprezanja povezan s prirastom tenzora deformacija $d\boldsymbol{\varepsilon}$ kroz konstitutivne relacije. Nestabilnost se može revidirati promjenom interesnog područja deformacije. Time se može utjecati na numeričku stabilnost kao i na točnost proračunskog modela [39].


5. METODOLOGIJA

Kod mehaničkih ispitivanja mogu se mjeriti dvije osnovne veličine, od kojih se jedna mjeri, a druga kontrolira. Najčešće su to sila i pomak, iz kojih se onda preko određenih izraza izračunavaju naprezanja i deformacije. Sila se mjeri pomoću specijalnih mjernih doza, a pomak se može mjeriti na više načina. U nastavku je prikazan pregled nekoliko metoda za mjerenje pomaka, te dobivanje deformacija. Od opisanih metoda u radu je korišten videoekstenzometar i korelacija digitalne slike.

5.1. Ekstenzometar

Uređaj koji se koristi za mjerenje relativnog pomaka dviju odabranih točaka na epruveti (uzorku) naziva se ekstenzometar. Vrlo često se primjenjuje kod statičkih vlačnih testova za dobivanje odnosa naprezanje–deformacija. Postoje dvije glavne vrste ekstenzometara: kontaktni i beskontaktni.

- **Kontaktni** – u izravnom su dodiru s površinom uzorka. Već se dugo primjenjuju, a najznačajniji su „clip on“ i „sensor arm“ ekstenzometri.
- **„Clip on“ekstenzometar** – ekstenzometar koji se kopčom pričvršćuje na uzorak. Primjenjuje se za precizna mjerenja deformacija. Dolaze u setovima, ovisno o mjernim područjima. Mogu mjeriti od vrlo malih pomaka, do relativno velikih (manje od 1 mm, te preko 100 mm), no to vrijedi za cijeli set. Što znači da pojedinačno imaju relativno usko mjereno područje. Prednost im je niska cijena i jednostavna primjena, a nedostatak im je ograničeno područje mjerenja i pojava zareznog djelovanja na mjestu kontakta s uzorkom, gdje može doći do oštećenja. Zbog krhke konstrukcije, neke izvedbe ekstenzometara potrebno je odspojiti prije nego što dođe do loma epruvete, da ih ne oštete udarne sile nastale kod loma [45]. Primjer mjerenja ovim ekstenzometrom prikazan je na slici 9.




Slika 9. Mjerenje „clip on“ ekstenzometrom [46]

- „*Sensor arm*“ ekstenzometar – automatski putujući ekstenzometar. Jedan takav ekstenzometar zamjenjuje cijeli set „clip on“ ekstenzometara. Ovi ekstenzometri osiguravaju puno bolju ponovljivost rezultata i imaju zanemariv utjecaj na uzorak. Mjerno područje im je vrlo široko (do 1000 mm), bez ikakvog gubitka točnosti. Rezolucija pomaka im je 0,3 μm ili manja (do 0,02 μm kod najkvalitetnijih uređaja). Otporniji su na udarnu silu od mehaničkih ekstenzometara, no kod većih opterećenja potrebno ih je odspojiti (prije loma epruvete) da ne bi došlo do oštećenja [47]. Mjerenje ovim ekstenzometrom prikazano je na slici 10.




Slika 10. Mjerenje „sensor arm“ ekstenzometrom [48]

- **Beskontaktni** – ekstenzometri koji nisu u neposrednom kontaktu s površinom uzorka. Nedostaci kontaktnih ekstenzometara jednostavno su uklonjeni razvojem beskontaktnih metoda mjerenja. Kod ovih metoda mjerenje pomaka i deformacija provodi se optičkim putem. Napredak beskontaktnih metoda mjerenja naglo se ubrzao razvojem digitalnih kamera visoke rezolucije i brzog prijenosa podataka u kombinaciji s vrlo snažnim algoritmima za analizu digitalnih slika. Najznačajniji su laserski i videoekstenzometar [47].
- **Laserski ekstenzometar** – za mjerenje deformacija epruveta podvrgnutih statičkom vlačnom ispitivanju. Nije potrebno markerima označavati mjerno područje uzorka već se ono osvjetli laserskom zrakom. Reflektirane zrake s površine uzorka padaju na CCD senzor digitalne kamere i obrađuju se pomoću složenih algoritama. Mjerno područje može biti do 900 mm s rezolucijom 0,1 μm što je dovoljno za najzahtjevnija ispitivanja. Primarno se koriste za ispitivanja osjetljivih materijala koje bi obični ekstenzometri s kopčom mogli oštetiti ili svojom masom utjecati na njihova mehanička svojstva, budući da ih je potrebno fizički pričvrstiti na epruvetu. Laserski ekstenzometri mogu se koristiti za ispitivanja na povišenim, te na sniženim temperaturama (ispod 0°C) [47]. Mjerenje ovim ekstenzometrom prikazano je na slici 11.




Slika 11. Mjerenje laserskim ekstenzometrom [48]

- **Videoekstenzometar** – metoda kojom se mjere pomaci/ deformacije snimanjem epruvete tijekom ispitivanja pomoću digitalne video kamere spojene s računalom. Može se koristiti jedna ili više kamera. Uzorak se izreže u poseban oblik pogodan za ispitivanje. Nakon toga se mjerna površina označi markerima (lijepljenjem, ucrtavanjem i sl.). Oni se razlikuju od tekstone uzorka i računalno ih lako prepoznaje. Udaljenost između markera definirana je određenim brojem piksela te se tijekom ispitivanja ta udaljenost konstantno prati. Na osnovu izmjerene udaljenosti računaju se deformacije. Prije mjerenja potrebno je provesti kalibraciju sustava, kako bi se odredilo koliko piksela čini 1 mm. Tada se udaljenost u pikselima prati u stvarnom vremenu, te poznavajući faktor kalibracije, može se direktno odrediti vrijednost deformacije. Ispravnom kalibracijom i dobrim algoritmima za analizu slike, može se postići rezolucija manja od 1 μm . Ispravnost kalibracije ovisi o posebnom uzorku prema kojem se provodi kalibracija. Vrlo je bitno pripremiti ga s posebnom preciznošću. Kalibracija se provodi na način da se prvo uslikaju slike s kalibracijskim uzorkom, digitaliziraju, a zatim se pod istim uvjetima slikaju ostali uzorci. Za mjerenja kod kojih je potrebna velika točnost, videoekstenzometri su provjereno dobra opcija. Mogu mjeriti deformacije u širokom rasponu, što omogućuje npr. određivanje modula elastičnosti ili deformacije kod loma. Mjenjanjem uvjeta osvjetljenja kod videoekstenzometra može utjecati na rezultate ispitivanja ako se ne koriste odgovarajući filteri. Također, mogu se koristiti za mjerenja u širokom temperaturnom području [47].
- Za potrebe istraživanja u ovom radu je korišten videoekstenzometar kao metoda za određivanje pomaka i deformacija. Uz ovu metodu, za provjeru točnosti rezultata korištena je i metoda korelacije digitalne slike o kojoj će biti riječi u nastavku rada. Primjer mjerenja ovom metodom prikazan je na slici 12.

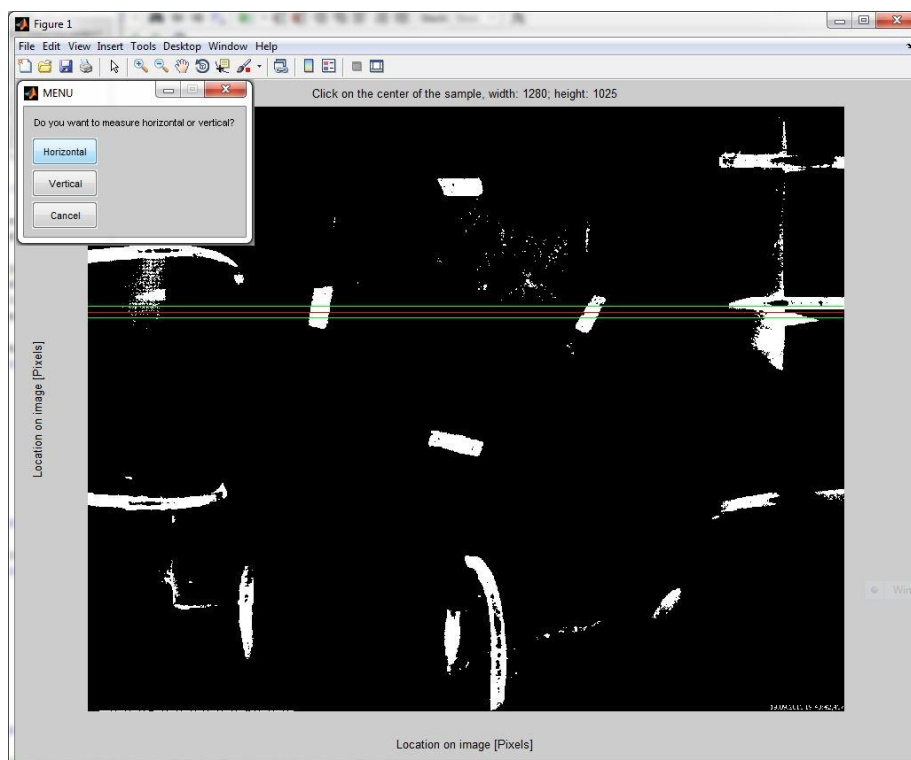


Slika 12. Mjerenje pomaka videoekstenzometrom

Algoritam za analizu slike tj. za praćenje promjene udaljenosti dvaju markera preuzet je sa stranice „Matlab Central“ [49]. Navedeni algoritam prati pomake između dviju odabranih točaka (markera). Uz to ima još niz mogućnosti, i sve su komercijalno dostupne. No prije početka, važno je napomenuti nekoliko stvari. Najprije, algoritam radi na principu raspoznavanja bijelog uzorka na crnoj pozadini. To znači da je originalne slike potrebno pretvoriti u crno bijele, s tim da je pozadina crna, a markeri bijeli (slika 13.). Treba dobiti što bolji kontrast, da algoritam može što lakše prepoznati markere. Sljedeći korak je stvaranje liste niza slika koje je potrebno analizirati (eng. *Generate file list*). Slijedi odabir smjera analize (horizontalno ili vertikalno). U ovom slučaju prikazana je horizontalna linija mjerenja (slika 14.), no provedena je i vertikalna, budući da se radi o dvoosnom vlačnom ispitivanju.

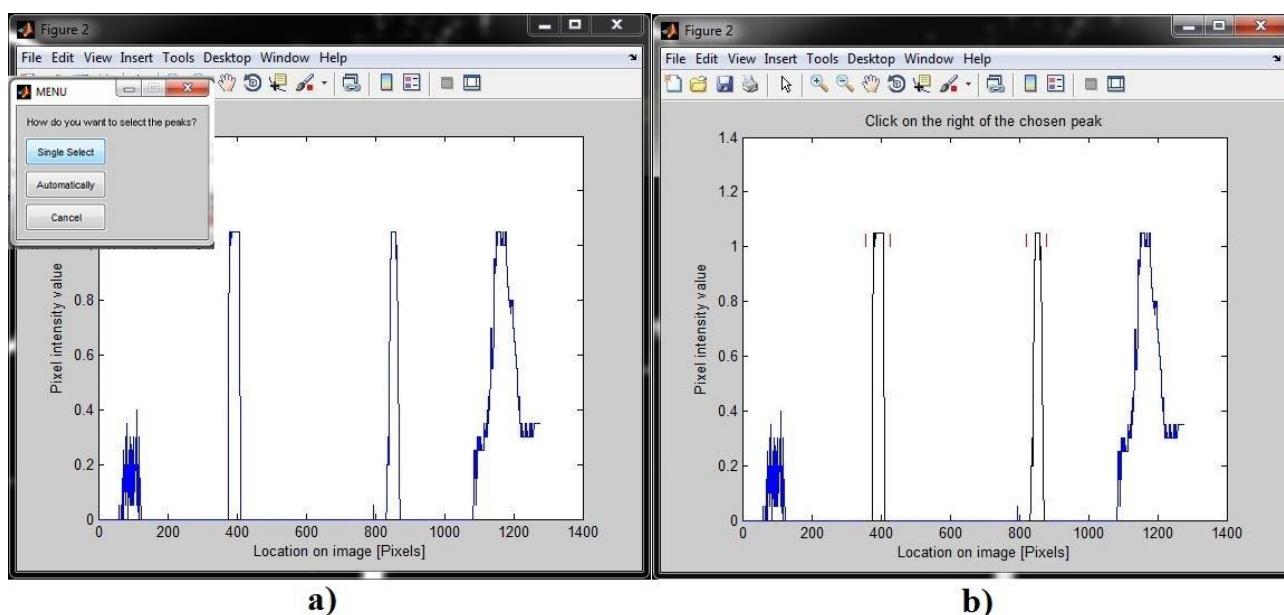


Slika 13. Primjer crno – bijele slike uzorka korištene u analizi pomaka i deformacija videoekstenzometrom



Slika 14. Linija mjerenja

Nakon toga od svih prepoznatih bijelih uzoraka na liniji mjerenja, slijedi odabir onih referentnih čiji će se pomaci pratiti (opcija „Single select“), (slika 15. a). Odabiru se dva markera (opcija „One more“). Tu treba pripaziti da se odaberu oni pravi (koji označavaju markere) jer na slici ima i drugih bijelih uzoraka koji nisu markeri (slika 15. b).



Slika 15. Prepoznavanje bijelih uzoraka na liniji mjerenja: a) svi uzorci vidljivi na liniji mjerenja, b) odabrani markeri

Odabirom markera, kreće analiza pomaka. Kao izlazni podaci dobivaju se pomaci dvaju odabranih markera (eng. „peak positions“). Deformacije su naknadno izračunate prema formuli $\varepsilon = \Delta L / L$, gdje je $\Delta L = L - L_0$, $L = u_2 - u_1$, a L_0 je početna udaljenost između markera. Kako se radi o dvoosnom vlačnom testu, isti je postupak za horizontalni i vertikalni smjer. Dobivene deformacije kasnije se koriste za usporedbu s metodom korelacije digitalne slike.


5.2. Korelacija digitalne slike

Korelacija digitalne slike je metoda razvijena početkom 80-ih godina prošlog stoljeća na Sveučilištu u Južnoj Karolini, a sve brže se razvija napretkom računalne tehnologije i digitalnih kamera. Ova metoda koristi digitalne slike za mjerenje pomaka i deformacija tijela pod opterećenjem. Slike se snimaju prije, tijekom i nakon opterećenja, te se naknadno obrađuju. To je bezkontaktna optička metoda, dakle ne zahtijeva fizički kontakt s mjernim uzorkom, već je korištenjem kamera visoke razlučivosti omogućeno praćenje promjena stanja površine na mjernom uzorku. Snimljene digitalne slike koriste se za mjerenje cijelog polja pomaka za razliku od mjerenja ekstenzometrima i mjernim trakama koje mjere pomak samo u pojedinačnim točkama. Osim toga, omogućeno je mjerenje kontura, deformacija, vibracija i naprezanja na gotovo bilo kojem materijalu. Tehnika se može koristiti za mnogo testova uključujući vlačni, torziju, savijanje i kombinirano opterećenje za statičke i dinamičke primjene, a mjerno područje je vrlo široko. Mogućnost praćenja promjena na mikro i nano razini velika je prednost u odnosu na standardne metode mjerenja, a zbog jednostavne primjene i implementacije ova metoda sve više dobiva na popularnosti.

DIC se pokazao vrlo učinkovit u otkrivanju deformacija u mikroskopskim mehaničkim ispitivanjima. Za primjenu DIC-a vrlo je važno imati raznoliku teksturu površine uzorka kako bi se osigurao što veći kontrast potreban za međusobno povezivanje slika i praćenje pomaka. Kontrast se najčešće osigurava primjenom rastera (sitne čestice boje ili praha na mjernoj površini uzorka), a rjeđe se koristi prirodna tekstura materijala. Nanošenje rastera izvodi se finim, stohastičkim raspršivanjem boje pod tlakom.


5.2.1. Oprema za DIC

Za provedbu DIC metode nije potrebno mnogo opreme. Tek jedna kamera visoke razlučivosti za 2D ispitivanje, ili dvije kamere za 3D ispitivanje, te jedno računalo za obradu podataka. Postupak se sastoji od snimanja površine ispitnog uzorka, slike se digitalno obrađuju i spremaju u računalo (slika 16.).



Slika 16. Oprema za DIC metodu

Kamera ima CCD čip koji ima fotoosjetljive diode i velik broj piksela kako bi se mogle pratiti promjene na površini uzorka tijekom ispitivanja. Uloga računala je obrada odnosno pronalaženje identičnih piksela u nizu slika. Slike su crno-bijele (eng. *grayscale*), te u ovom koraku dolazi do problema jer se nijansa sive jednog piksela na jednoj slici može poklopiti na više piksela kod druge slike prilikom usporedne analize. Da bi računalo prepoznalo određeni piksel na dvjema slikama koristi se metoda korelacije. Kod ove metode primjenjuje se polje piksela tj. promatraju se susjedni pikseli kako bi se točno odredio onaj traženi piksel u nizu slika. Više o metodi u sljedećem potpoglavlju. Svaki piksel ima svoju vrijednost sive skale boja (intenziteta svjetlosti), te mu se dodjeljuje brojčana vrijednost. Brojem 0 označava se potpuno taman piksel, a brojem 100 potpuno bijeli piksel (slika 17.). Prilikom snimanja slika vrlo je važno koristiti adekvatno osvjetljenje koje će davati jednak intenzitet svjetlosti za vrijeme trajanja ispitivanja [50].




Slika 17. Detekcija piksela poljem piksela [50]

5.2.2. Koncepti DIC metode


a) Lokalni pristup

Kako bi se odredili pomaci i deformacije uzorka, uzastopne slike se međusobno uspoređuju tako da se traže točke podudaranja. Kako je gotovo nemoguće pronaći točku koristeći samo jedan piksel, koristi se polje piksela (eng. *subset*) ili fasete (eng. *facets*), veličine od npr. 20x20 piksela. Svako polje piksela ima jedinstvenu vrijednost sive skale boja (intenzitet svijetlosti) i pretpostavlja se da se ta vrijednost ne mijenja tijekom deformiranja. Polja su najčešće pravokutnog ili kvadratičnog oblika. Pomak polja piksela utvrđuje se na deformiranoj slici tražeći polje s jednakom vrijednošću sive skale. Kad se nađe polje, može se odrediti njegov pomak. Kako bi se ovaj postupak mogao provesti površina uzorka mora imati određeni kontrast, koji se postiže tretiranjem površine bojom (najčešće) s ciljem dobivanja stohastičkog rastera, kao što je već ranije spomenuto u tekstu. Na slici 18. prikazan je primjer rastera i polja piksela na referentnoj i deformiranoj slici. Crni markeri uz rub mjerene površine uzorka korišteni su za mjerenje pomaka videoekstenzometrom.



Slika 18. Primjer stohastičkog rastera nanesenog na ispitni uzorak i označeno polje piksela na referentnoj (a) i deformiranoj slici (b)

Usporedba položaja polja piksela u referentnoj i deformiranoj konfiguraciji (slika 19.) provodi se pomoću jednadžbi za korelaciju digitalne slike primjenom određenih korelacijskih faktora i matematičkih kriterija usporedbe.



Slika 19. Referentna i deformirana konfiguracija

Općenito, ako se s $f(x,y)$ označi raspodjela intenziteta sive boje na referentnoj slici, a sa $g(x',y')$ raspodjela intenziteta sive boje na slici deformiranog ispitnog uzorka, tada se princip korelacije može definirati kao preslikavanje Z iz referentne u deformiranu konfiguraciju

$$f(x, y) = Z[g(x', y')], \quad (17)$$

gdje je

$$\begin{aligned} x' &= x + u_x(x, y), \\ y' &= y + u_y(x, y). \end{aligned} \quad (18)$$

Koordinate točke B' (x'_B, y'_B) u deformiranoj konfiguraciji mogu se izraziti preko koordinata u referentnoj konfiguraciji uz pretpostavku da su gradijenti pomaka konstantni u cijelom polju piksela. Tada se koordinate (x'_B, y'_B) mogu zapisati kao

$$\begin{aligned} x'_B &= x_A + u_{x,A} + \frac{\partial u_{x,A}}{\partial x} \Delta x + \frac{\partial u_{x,A}}{\partial y} \Delta y, \\ y'_B &= y_A + u_{y,A} + \frac{\partial u_{y,A}}{\partial x} \Delta x + \frac{\partial u_{y,A}}{\partial y} \Delta y. \end{aligned} \quad (19)$$

Za Δx i Δy vrijedi [Slika 19.]:

$$\begin{aligned} \Delta x &= x_B - x_A, \\ \Delta y &= y_B - y_A. \end{aligned} \quad (20)$$

Točke A i B u referentnoj konfiguraciji preslikavaju se u točke A' i B' u deformiranoj konfiguraciji pri čemu se promjena položaja točke A u A' interpretira kao pomak, a koordinate točke B' su dane izrazima (3). Koeficijent koji predstavlja kriterij podudarnosti dviju raspodjela intenziteta sive boje između dva polja pomaka naziva se korelacijski koeficijent C . Ovaj koeficijent je za slučaj dvodimenzijskog mjerenja, funkcija 6 varijabli, dvije komponente pomaka $u_{x,A}$ i $u_{y,A}$ i četiri gradijenta pomaka $\partial u_{x,A} / \partial x, \partial u_{x,A} / \partial y, \partial u_{y,A} / \partial x, \partial u_{y,A} / \partial y$. Korelacijski koeficijent uvijek poprima ekstremne vrijednosti, dakle traži se njegov minimum ili maksimum ovisno o kojem se tipu koeficijenta radi. Postoji nekoliko tipova korelacijskih koeficijenata od kojih su najznačajniji CC (eng. „cross – correlation“) koeficijent i SSD (eng. „sum squared difference“) koji se temelji na izračunu zbroja kvadrata razlike vrijednosti. Matlab algoritam koji je korišten u ovom radu za analizu pomaka kroz nizove digitalnih slika koristi upravo SSD korelacijski koeficijent.

SSD korelacijski koeficijent definiran je izrazom

$$C = 1 - \frac{\sum_{m,n} [f(x_m, y_n) - \bar{f}] [g(x'_m, y'_n) - \bar{g}]}{\sqrt{\sum_{m,n} [f(x_m, y_n) - \bar{f}]^2 \sum_{m,n} [g(x'_m, y'_n) - \bar{g}]^2}}, \quad (21)$$

gdje su \bar{f} i \bar{g} srednje vrijednosti matrica \mathbf{F} i \mathbf{G} . Spomenute matrice predstavljaju vrijednosti intenziteta nijansi sive boje svih piksela koji se nalaze unutar polja u referentnoj i deformiranoj konfiguraciji, pri čemu m predstavlja broj piksela u vertikalnom smjeru, a n broj piksela u horizontalnom smjeru. Općeniti zapis matrica \mathbf{F} i \mathbf{G} dan je izrazima:

$$\mathbf{F} = \begin{bmatrix} f_{1,1} & \cdots & f_{1,n} \\ \vdots & \ddots & \vdots \\ f_{m,1} & \cdots & f_{m,n} \end{bmatrix}, \quad \mathbf{G} = \begin{bmatrix} g_{1,1} & \cdots & g_{1,n} \\ \vdots & \ddots & \vdots \\ g_{m,1} & \cdots & g_{m,n} \end{bmatrix}. \quad (22)$$

Postupak korelacije se u stvari svodi na usporedbu stupnja preklapanja dviju matrica. Važno je napomenuti da se prethodno opisan princip metode korelacije digitalne slike, naziva lokalni pristup korelacije digitalne slike. Dakle, taj pristup podrazumijeva diskretizaciju digitalnih slika poljima piksela koji se nazivaju fasetama pri čemu centar fasete predstavlja mjernu točku [23]. Interpolacijom centara faseta dobiva se cijelo polje pomaka. Minimalna veličina faseta je 10x10 piksela ili više.

b) Globalni pristup

Globalni pristup temelji se također na diskretizaciji slike poljima piksela (fasetama), no mjerne točke predstavljaju vrhovi faseta. Tako se fasete tretiraju ovisno jedna o drugoj, što kod lokalnog pristupa nije slučaj. Zbog toga se vrijeme računanja povećava, ali su rezultati pouzdaniji. Minimalna veličina faseta kod ove metode je 4x4 piksela.

Svaka metoda ima određeni nedostatak, pa tako i DIC. Naime, prilikom zapisivanja slika sive razine skale boja, javljaju se brze fluktuacije polja pomaka koje su unesene konstantnim šumom kamere i mjernim postavom. Te fluktuacije se registriraju i ostaju zabilježene na slikama. One predstavljaju velik problem prilikom mjerenja malih pomaka jer najmanja promjena mjerenog pomaka uzrokuje vidljivu razliku mjerene veličine. Tu je potrebno uvesti pojam rezolucija pomaka, koji predstavlja najmanji pomak koji se može registrirati. Da li je registrirani pomak stvaran ili je uzrok neka nemehanička fluktuacija, potrebno je utvrditi. Zato je vrlo bitno pronaći kompromis između standardne mjerne nesigurnosti i rezolucije pomaka. Za rješavanje ovog problema razvijene su različite metode. Klasične metode su lokalni i globalni pristup, koji su prethodno opisani.

c) Regularizirani pristup

Kako bi se povećala pouzdanost rezultata (smanjila rezolucijska nesigurnost) razvijena je nova metoda temeljena na globalnom pristupu. Razvili su je Tomičević, Hild i Roux na *LMT Cachan* u Parizu, Francuska [51]. Zasniva se na mehaničkoj regularizaciji polja pomaka, kojom se filtriraju sve fluktuacije koje nisu mehanički podatljive. Dakle, ona služi kao filter za propuštanje samo mehaničkih polja prilikom čega se zanemaruje šum koji se javlja prilikom zapisivanja slika. Prednost regularizacijskog algoritma posebno je vidljiva kod analize siromašnih tekstura (niska razina sive skale) [24].

U ovom istraživanju korišten je navedeni regularizacijski DIC algoritam koji koristi trokutaste elemente (T3) s linearnom interpolacijom pomaka (RT3 – DIC). Temelji se na globalnom pristupu korelacije digitalne slike i mehaničkoj regularizaciji polja pomaka, a u nastavku slijedi kratak opis teorije ove regularizacijske metode.

Prilikom zabilježavanja dvije slike u referentnoj (f) i deformiranoj konfiguraciji (g) vrijedi

$$f(\mathbf{x}) = g(\mathbf{x} + \mathbf{u}(\mathbf{x})), \quad (23)$$

gdje je \mathbf{u} nepoznato polje pomaka, a \mathbf{x} lokacija piksela. Traženo polje pomaka minimizira sumu razlike kvadrata korelacijskog reziduala (Φ_c^2) preko cijele površine unutar koje se pomaci prate. Ta površina naziva se ROI (eng. „region of interest“), a zapis glasi

$$\Phi_c^2 = \int_{ROI} \left(|g(\mathbf{x} + \mathbf{u}(\mathbf{x})) - f(\mathbf{x})| \right)^2 d\mathbf{x}. \quad (24)$$

Ako ne postoje neki dodatni uvjeti nemoguće je odrediti pomak svakog piksela nezavisno jer postoje dvije nepoznanice za danu razliku sive skale. Zbog toga je odabrana slaba formulacija polja pomaka izražena preko određene baze

$$\mathbf{u}(\mathbf{x}) = \sum_n u_n \psi_n, \quad (25)$$

gdje je ψ_n odabrana funkcija oblika, a u_n pripadajući stupnjevi slobode polja pomaka. Mjereni problem se nadalje sastoji od minimiziranja Φ_c^2 s obzirom na u_n . Minimiziranje se provodi Newtonovim iteracijskim algoritmom, iterativnim rješavanjem linearnog sustava

$$[\mathbf{M}]\{\delta\mathbf{u}\} = \{\mathbf{b}\}. \quad (26)$$

Ako se primjenjuje linearna elastičnost, jednačbe ravnoteže su

$$[\mathbf{K}]\{\mathbf{u}\} = \{\mathbf{f}\}, \quad (27)$$

gdje je $[\mathbf{K}]$ matrica krutosti, a $\{\mathbf{f}\}$ vektor čvornih sila. U slučaju da polje pomaka ne zadovoljava jednadžbe ravnoteže uvodi se ravnotežna razlika (Φ_m^2).

Uslijed nedostatka čvornih sila, unutrašnji čvorovi su slobodni od svih vanjskih sila, stoga se metoda ravnotežne razlike sastoji od minimiziranja

$$\Phi_m^2 = \{\mathbf{u}\}^t [\mathbf{K}]^t [\mathbf{K}] \{\mathbf{u}\}, \quad (28)$$

gdje je t operator transponiranja, a Φ_m^2 odgovara sumi kvadratne norme svih ravnotežnih razlika, ali samo unutrašnjih čvorova. Stoga ova metoda zahtjeva dodatnu regularizaciju za rubne (vanjske) čvorove.

Zato postoji treća funkcija kojom se minimiziraju rubne fluktuacije

$$\Phi_b^2 = \{\mathbf{u}\}^t [\mathbf{L}]^t [\mathbf{L}] \{\mathbf{u}\}, \quad (29)$$

gdje je $[\mathbf{L}]$ operator koji ima utjecaj na rubu ROI-a.


Minimiziranje korelacijskog reziduala (Φ_c^2), ravnotežne razlike (Φ_m^2) i rubnih fluktuacija (Φ_b^2) zahtjeva uvođenje totalnog funkcionala Φ_t^2

$$(1 - w_m + w_b) \Phi_t^2 = \tilde{\Phi}_c^2 + w_m \tilde{\Phi}_m^2 + w_b \tilde{\Phi}_b^2, \quad (30)$$

gdje su w_m i w_b težine pridodane $\tilde{\Phi}_m^2$ i $\tilde{\Phi}_b^2$, a $\tilde{\Phi}$ označava normalizirane reziduale. Težine w_m i w_b su odabrane kao

$$w_m = (2\pi |\mathbf{k}| l_m)^4, \quad w_b = (2\pi |\mathbf{k}| l_b)^4, \quad (31)$$

gdje su l_m i l_b regularizacijske dužine za Φ_m^2 i Φ_b^2 . U slučaju da se zada viša vrijednost regularizacijske dužine l_m stavlja se veća težina na funkcional $\tilde{\Phi}_m^2$, te stoga ravnotežni reziduali moraju dosegnuti veću razinu. Isto vrijedi i za zadavanje regularizacijske dužine l_b za rubne reziduale [24]. U RT3 – DIC algoritmu korištenom u ovom radu regularizacijska dužina za unutarnje čvorove iznosila je $l_m = 128$ piksela, a za vanjske čvorove $l_b = 64$ piksela. Kriterij takvog odabira objašnjen je u sljedećem poglavlju. Primjer diskretizacije ROI-a T3 trokutastim elementima prikazan je na slici 20. Prosječna veličina jednog trokutnog elementa je oko 10 piksela. Veličine slika su 1280x1025 s 8 bitnom digitalizacijom.



Slika 20. Primjer diskretizacije ROI-a T3 trokutastim elementima na referentnoj (a) i deformiranoj slici (b)

U istraživanju su analizirana četiri uzorka svinjske aorte. Koristila se umjetno nanescena tekstura (stohastički raster). Kod prva tri uzorka promatrani su samo središnji dijelovi, a kod četvrtog uzorka cijela površina (gotovo u cijelosti). U skladu s tim upotrijebljene su odgovarajuće veličine mreža. Mreže za prva tri uzorka su vrlo slične veličine, dok je mreža za četvrti uzorak mnogo veća.

Brojevi čvorova u mreži svakog uzorka prikazani su u tablici 1.

Tablica 1. Broj čvorova u mreži svakog uzorka

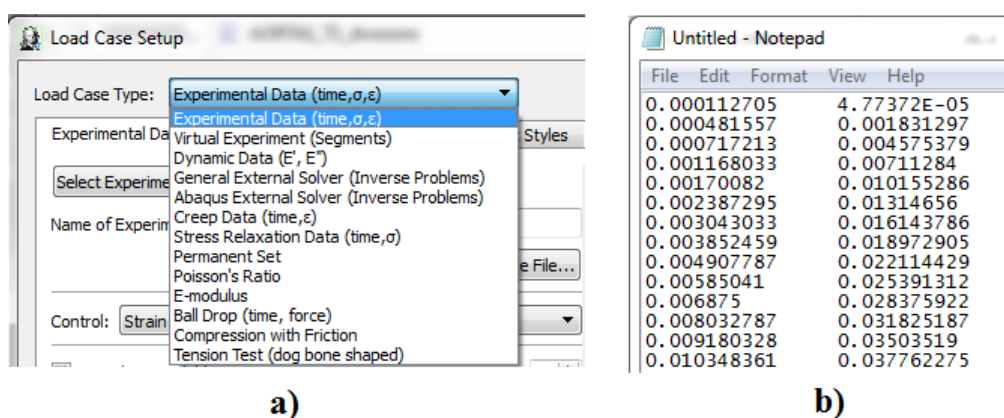
Uzorak	Čvorovi		
	Unutarnji	Vanjski	Ukupno
1	1166	140	1306
2	1070	135	1205
3	1318	151	1469
4	6476	325	6801

5.3. Verifikacija odabranih hiperelastičnih materijalnih modela i određivanje parametara materijala

5.3.1. Uvod u MCalibration

Programski paket *MCalibration* je alat koji omogućava jednostavno i brzo određivanje parametara materijala za odabrani materijalni model koristeći učitane eksperimentalne podatke. Svi modeli navedeni u potpoglavlju 4.2.1. mogu biti kalibrirani ovim programskim alatom. Odlikuje se jednostavnim i intuitivnim grafičkim sučeljem prilagođenim svakom korisniku. Uz to nije zahtjevan za računalo i ne zauzima mnogo prostora, što je velika prednost u usporedbi sa programskim paketima koji rade na principu MKE.

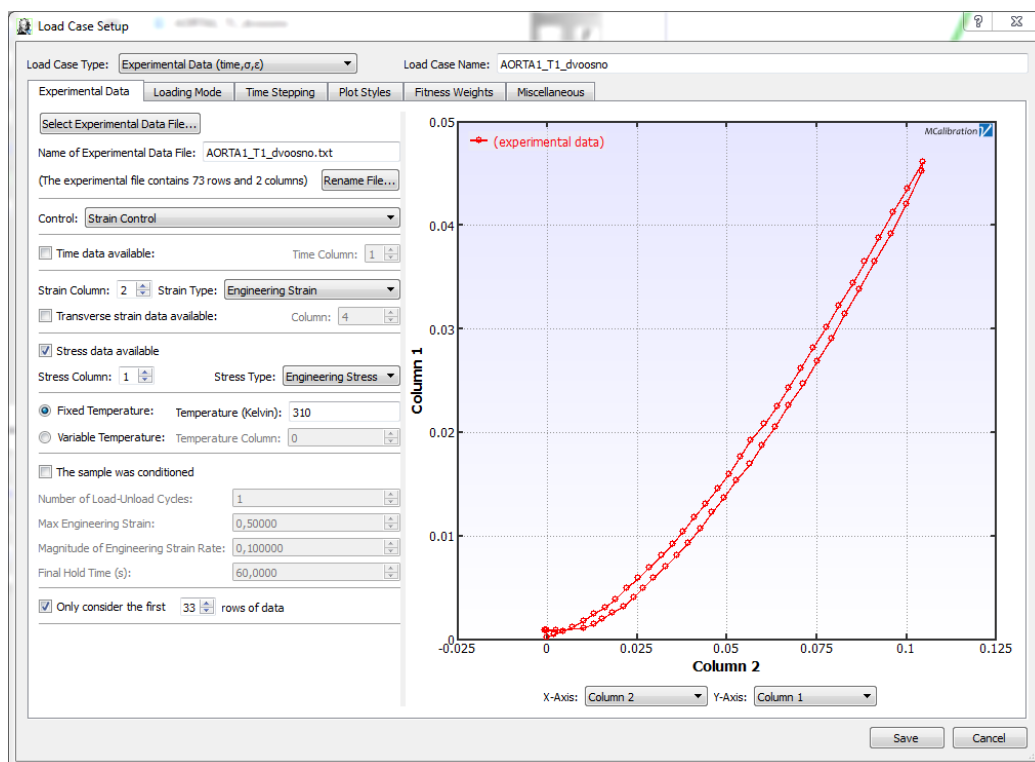
Glavni prozor programa sastoji se od 5 izbornika od kojih je najbitniji *Calibrate* u kojem se provodi kalibriranje. Učitavanje podataka je prvi korak u cilju kalibriranja željenog materijalnog modela. Moguće je učitati setove podataka, ovisno o vrsti eksperimenta i dostupnim podacima o materijalu (slika 21. a). Jedan od načina je učitavanje iz tekstualne datoteke. U ovom slučaju dostupni podaci su inženjerska naprezanja (prvi stupac) i pripadajuće deformacije (drugi stupac, slika 21. b).



Slika 21. Odabir seta podataka (a), primjer učitanih podataka (b)

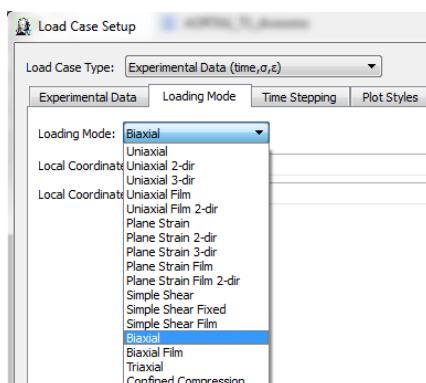
Učitavanje i podešavanje podataka u izborniku *Calibrate* vrši se odabirom ikone *Add a Load Case*. Za kalibriranje su korišteni eksperimentalni podaci uzorka AORTA 1 za fazu *test1*. Pošto se radilo o biaksijalnom testu, podaci u A i T smjeru su uprosječeni kako bi se dobio jedan set podataka. Nakon odabira odgovarajućeg seta podataka (eng. *Experimental Data(time, σ , ϵ)*) i učitavanja tekstualne datoteke s podacima (eng. *Select Experimental Data File...*) program automatski iscrtava dijagram. Slijedi odabir postavki (slika 22.). Pošto u podacima nije sadržano vrijeme (eng. *Time data available*), ta postavka je isključena.

Pod opcijom *Control* odabrano je *Strain Control* budući da je tijekom testa prate pomaci odnosno deformacije. Nadalje, podešeni su stupci (eng. *Stress i Strain Column*), temperatura i broj podataka koji se uzimaju u obzir. Broj podataka namješten je na 33 (samo opterećenje, vrijedi isključivo za fazu *test1* uzorka AORTA 1), budući da hiperelastični materijalni modeli ne mogu opisati histerezu.




Slika 22. Odabir postavki za učitane podatke

Sljedeći korak je odabir vrste opterećenja. Dostupno je mnogo mogućnosti. Kako je u ovom radu analiziran slučaj dvoosnog opterećenja te su za taj slučaj dobiveni eksperimentalni podaci, odabrano je dvoosno opterećenje (eng. *Biaxial*), (slika 23.). Ukoliko postoje eksperimentalni podaci za ostala stanja naprezanja (jednoosno, ravninsko stanje deformacija, posmično i dr.), oni se na jednak način mogu učitati i kalibrirati. Eksperimentalni podaci mogu se prikazivati istodobno ili pojedinačno, što nudi mogućnost usporedbe i provjere greške.



Slika 23. Odabir vrste opterećenja

Nakon definiranja opterećenja slijedi odabir materijalnog modela za kalibraciju. *MCalibration* sadrži vlastitu bazu materijalnih modela koja se naziva *PolyUMod*. Uz nju su implementirane i baze modela koje sadržavaju programski paketi *Abaqus* i *ANSYS*. U svrhu ovog rada korišteni su *Abaqus* – *Hyperelastic* modeli (*Neo – Hooke*, *Mooney – Rivlin* i *Ogden*), (slika 24.).



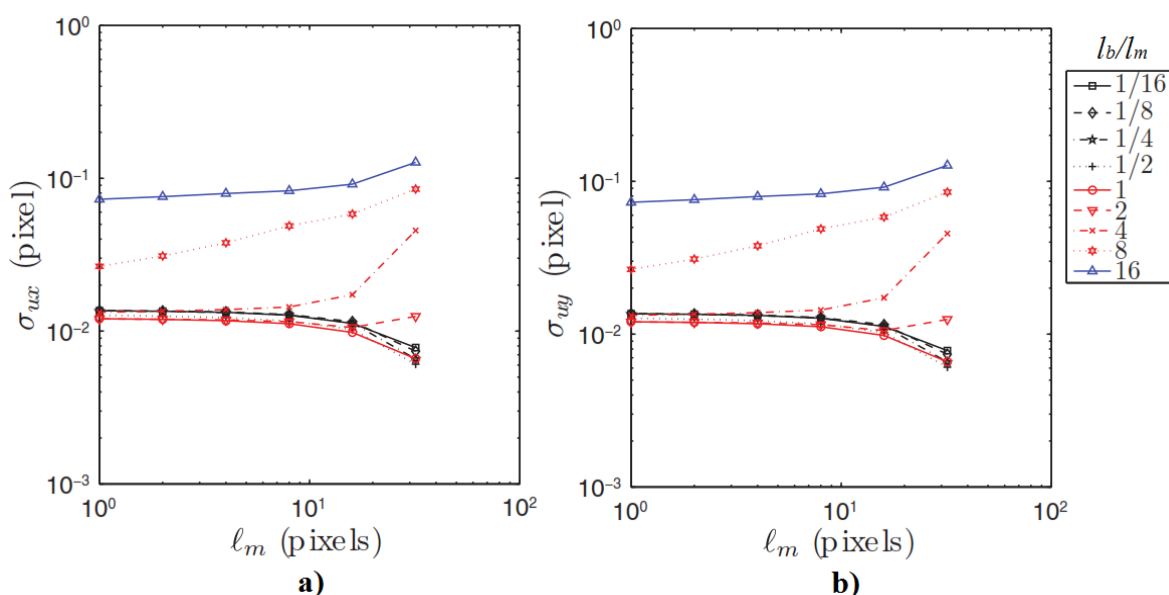
Slika 24. Odabir materijalnog modela

Kalibracija se pokreće odabirom ikone *Run Calibration*. Kalibrirani materijalni model (ukoliko je zadovoljavajući) može se eksportirati u *Abaqus* ili *ANSYS* pomoću opcije *Export Model*. Datoteka se sprema u odgovarajućem formatu koji se može učitati iz navedenih programa. Učitavanjem datoteke, materijalni model se importira u *Model tree* i spreman je za korištenje u numeričkim analizama.

6. PARAMETARSKA ANALIZA REZOLUCIJE POMAKA

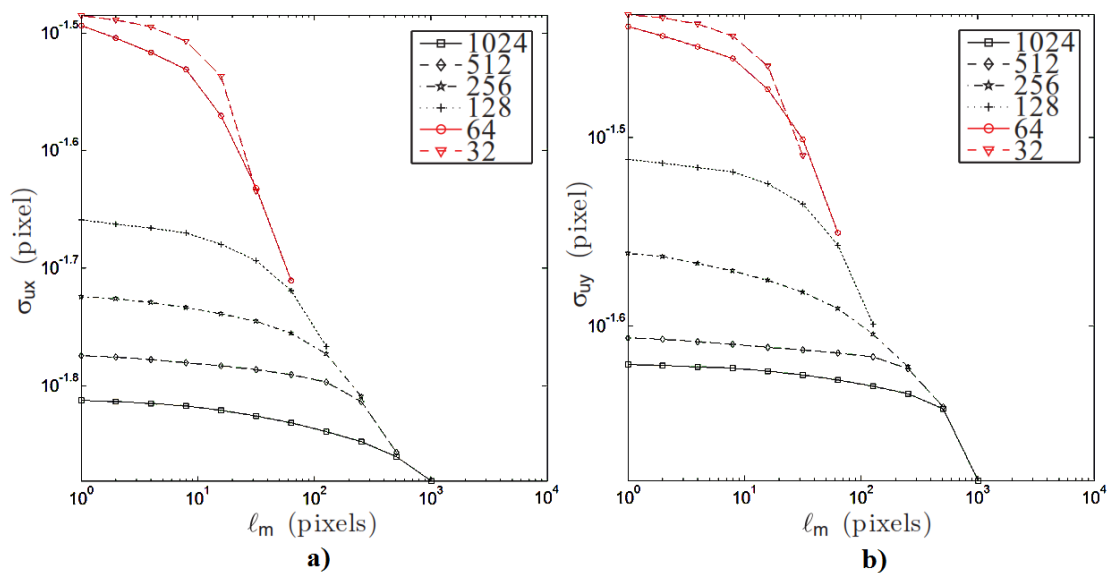
Rezolucija pomaka je najmanji pomak koji se može registrirati regularizacijskim algoritmom. U tom smislu, kako bi se odredili regularizacijski parametri za dobivanje najpouzdanijih rezultata potrebno je provesti parametarsku analizu rezolucije pomaka. Već je spomenuto da je odabrana regularizacijska dužina za unutrašnje čvorove iznosila $l_m = 128$ piksela, a za vanjske čvorove $l_b = 64$ piksela. Najprije slijedi objašnjenje zašto je omjer regularizacijskih dužina $l_b / l_m = 1/2$, a zatim obrazloženje odabira regularizacijske dužine $l_m = 128$ piksela.

Na primjeru iz literature [24] su testirani omjeri l_b / l_m . Svrha određivanja omjera l_b / l_m je u tome da omjer u daljnjim analizama na stvarnim testovima bude konstantan. Za početnu vrijednost odabrano je $l_m = 32$ piksela pri čemu se on inkrementalno (INC=1) smanjivao (relaksirao) za 2 puta sve do vrijednosti $l_m = 1$ piksel. Jednostavnije rečeno, inkrement je korak koji predstavlja omjer smanjenja regularizacijske dužine. Ako je npr. vrijednost inkrementa INC=1 regularizacijska dužina se svakim sljedećim korakom smanjuje za pola. Iz dijagrama na slici 25. vidljivo je da je za omjere od 1 do 1/16 standardna greška između mjerenog i generiranog polja pomaka približno jednaka te je zbog toga odabran omjer od 1/2 koji daje najmanju grešku. Za sve krivulje relaksacijski proces se čita s desna na lijevo.



Slika 25. Standardna greška pomaka za različite regularizacijske dužine i različite omjere l_b/l_m u smjeru osi x (a) i u smjeru osi y (b) [24]

Kao što je već napomenuto, rezolucija pomaka predstavlja najmanji pomak koji se može registrirati mjernom metodom u ovom slučaju regularizacijskim algoritmom. To je vrlo bitno naglasiti kako bi se razjasnio odabir regularizacijske dužine $l_m = 128$ piksela. Na slici 26. prikazana je promjena standardne greške pomaka σ_u za različite regularizacijske dužine l_m i za dvije komponente pomaka (u horizontalnom (σ_{ux}) i vertikalnom (σ_{uy}) smjeru).




Slika 26. Promjena standardne greške pomaka za različite regularizacijske dužine l_m uz omjer $l_b/l_m=1/2$ u smjeru osi x (a) i u smjeru osi y (b)

Dijagrami su dobiveni pomoću algoritma za parametarsku analizu rezolucije pomaka u programskom paketu *Matlab*. Primjenjujući različite početne regularizacijske dužine vidljivi su različiti trendovi. Može se primjetiti i zaključiti da što je veća regularizacijska dužina manja je rezolucija pomaka (manja mjerna nesigurnost). U prijašnjim istraživanjima pokazano je da velike regularizacijske dužine mogu utjecati na rezoluciju pomaka tj. mogu utjecati na „brisanja“ malih pomaka [Slika 26.]. Dakle, odabir regularizacijske dužine ovisi i o iskustvu korisnika koji provodi RT3-analizu. U ovom slučaju, kako se radi o maksimalnim deformacijama uzorka u rasponu 20-30%, iskustveno je odabrana srednja vrijednost regularizacijske dužine $l_m = 128$ piksela. Time je osigurano da nema utjecaja „brisanja“ malih pomaka. Prikazani dijagrami na slici 26. dobiveni su za uzorak 1, ali zaključci vrijede i za ostale uzorke budući da im je tekstura slična.


Za bolje razumijevanje pojma „brisanja“ pomaka, na slici 27. prikazan je primjer polja reziduala (grešaka) za dvije regularizacijske dužine ($l_m = 128$ i $l_m = 1024$ piksela).

Na slici je vidljivo da je polje reziduala s $l_m = 128$ piksela glatko, odnosno u usporedbi s poljem reziduala s $l_m = 1024$ piksela manje je grešaka. Te greške predstavljaju nepoželjne pomake koji se „brišu“ i u daljnjim analizama se ne uzimaju u obzir.



Slika 27. Polja reziduala (grešaka) kod $l_m = 1$ piksel s početnom regularizacijskom dužinom $l_m = 128$ piksela (a) i $l_m = 1024$ piksela (b) [52]

Kao primjer, na slici 28. prikazano je polje reziduala s početnom regularizacijskom dužinom $l_m = 128$ piksela generirano za prvi uzorak AORTE 1. Polje korelacijskih reziduala je uniformno te je moguće zaključiti da je korelacijski algoritam uspješno konvergirao.



Slika 28. Polja reziduala (grešaka) kod $l_m = 1$ piksel s početnom regularizacijskom dužinom $l_m = 128$ piksela za uzorak AORTA 1

7. EKSPERIMENTALNO ISPITIVANJE

U sklopu ovog rada analizirana su četiri in vitro eksperimentalna ispitivanja svinjske aorte koja imaju za cilj dobivanje što boljeg uvida u mehaničko ponašanje krvnih žila uslijed narinutog dvoosnog mehaničkog opterećenja. Određivanje odziva materijala mjerenjem pomaka/deformacija na površini ispitnog uzorka poslužiti će za daljnji validaciju i identifikaciju parametara hiperelastičnih materijalnih modela. S obzirom da se ispitivanje odnosi na biološki meka tkiva potrebno je zadovoljiti određene standarde eksperimentalne procedure. Stoga se ispitivanje dijeli na pripremu i provedbu. U dio pripreme se ubrajaju svi postupci od zaprimanja uzoraka pa do njihovog postavljanja na mjerni uređaj, dok se pod provedbom podrazumijeva definiranje parametara ispitivanja, određivanje mjerne nesigurnosti, te praćenje i kontroliranje opterećenja uzorka tijekom ispitivanja.

Ispitivanja su provedena na Tehničkom sveučilištu u Grazu na ravninskoj dvoosnoj kidalici koja je posebno namijenjena za ispitivanja mekih bioloških tkiva i umjetnih materijala. Ispitni uređaj se sastoji od četiri linearna aktuatora od kojih se svaki može neovisno kontrolirati s obzirom na kontrolu pomaka, sile ili deformacije. Sila se mjeri pomoću mjernih senzora postavljenih na svakom aktuatoru. Maksimalna sila opterećenja je 100 N s rezolucijom od 0,6 mN dok je maksimalni pomak aktuatora 50 mm s rezolucijom od 0,1 μm . Najveća primjenjiva brzina opterećenja ograničena je na oko 30 mm/s. Ravninski dvoosni uređaj namijenjen je za vlačna ispitivanja te je digitalno upravljani preko programskog paketa „Test&Motion“ Version 2.0 proizvođača DOLI Elektronik, Njemačka.

7.1. Program opterećenja ispitnog uzorka


Provedeni ravninski dvoosni test je vlačno ispitivanje kod kojeg se uzorak opterećuje u dva međusobno okomita smjera. Navedeno eksperimentalno ispitivanje primjenjuje se za analizu mehaničkih karakteristika anizotropnih materijala poput kompozita, tekstila i bioloških tkiva. Razlikuju se tri glavne vrste biaksijalnog vlačnog ispitivanja

1. Napuhavanje – cilindrični uzorak se učvrsti na svojim krajevima a opterećenje se narine povećanjem unutrašnjeg tlaka do pucanja ispitnog uzorka. Medij kojim se mijenja tlak ispitnog uzorka može biti zrak ili voda.

2. Napuhavanje s dodatnom aksijalnom silom – cilindrični šuplji uzorak opterećen je aksijalnom silom i unutarnjim tlakom.

3. Ravninski biaksijalni test – uzorak se opterećuje u dva međusobno okomita smjera željenim intenzitetom sile ili pomaka.

U ovom radu uzet je u obzir isključivo ravninski dvoosni test na kojem su ispitani svježi uzorci svinjske aorte. Slika 29. prikazuje shemu eksperimentalnog ispitivanja analiziranog dvoosnog testa. Brojevima je označen raspored aktuatora koji će biti bitan prilikom definiranja orijentacije uzoraka. Uzorci su kvadratnog oblika, te su na svakom rubu postavljene po tri međusobno povezane udice/kukice. One služe kao prihvat između uzorka i ispitnog uređaja te prenose silu sa svakog aktuatora. Međusobno su povezane koncem. Korišteni postav temeljen je na sustavu kojeg je osmislio Eilaghi [53], a ciljano je razvijen za eksperimente na mekim tkivima. Eilaghi i dr. [53] proučavali su međusobni utjecaj oblika uzoraka i rubnih uvjeta uzimajući u obzir prijenos opterećenja preko udica i konca. Numeričke simulacije metodom konačnih elemenata pokazale su da je za najbolje rezultate (tj. homogeno polje pomaka u sredini uzorka) potrebno koristiti minimalno pet udica na svakom rubu uz jednak razmak između svake od njih. Također, udaljenost ruba uzorka od mjesta prihvata svake udice smije biti od 0,6 do 1 puta vrijednost udaljenosti između dviju udica. Ovi podaci su dobiveni istraživanjem [53] na uzorcima dimenzija 25x25 mm. Zona mjerene površine gdje se prate deformacije je oko 10x10 mm u središtu ispitnog uzorka. U ovom radu analizirani su eksperimenti gdje su za prihvat uzorka korištene tri udice na svakom rubu pošto je prvotni cilj bio primjena novih mjernih tehnika u području mekih tkiva. Kod tri uzorka promatrano je mjerno područje od 10x10 mm. Četvrti uzorak nije imao strogo definirane dimenzije zone interesa budući je cilj bio promatranje utjecaja prihvata (tj. broja udica) na mjereno polje pomaka i deformacija.



Slika 29. Shematski prikaz ravninskog dvoosnog ispitivanja uzorka svinjske aorte

Kod eksperimentalnog ispitivanja svakog materijala potrebna je odgovarajuća priprema ispitnih uzoraka. Kako se ovdje radi o mekom tkivu krvne žile, priprema ima posebnu važnost jer treba osigurati posebne uvjete ispitivanja zbog simulacije fizioloških uvjeta. Također, treba pripremiti površinu uzoraka za primjenu dvije optičke metode.


7.2. Priprema uzoraka

Priprema ispitivanja započinje zaprimanjem uzorka svježe svinjske aorte (Slika 30.). Uzorci tkiva pripadaju mladoj domaćoj svinji, a dobiveni su iz klaonice. Aorta je odvojena od srca u roku 3 sata od usmrćivanja svinje. Nakon toga, skladištena je u antibiotskoj otopini na 4°C do početka ispitivanja, kako bi se očuvala svojstva tkiva. U svrhu sprječavanja promjene materijalnih svojstava mekog tkiva vrlo je važno da se temperatura tkiva znatno ne mijenja i da se ispitivanje provede što prije nakon eksplantacije.



Slika 30. Svinjska aorta

Prije izrezivanja uzoraka uklonjeno je svo vidljivo vezivno tkivo s površine žile. Poslije čišćenja, žila je po dužini pažljivo razrezana skalpelom i izravnata (slika 31.).




Slika 31. Seciranje žile

Nakon toga izrezana su 4 uzorka približnih dimenzija 25x25 mm. Svi su uzorci pripremljeni u sterilnim uvjetima. Nakon pripreme između svakog ispitivanja preostali uzorci su skladišteni u antibiotskoj otopini na temperaturi 4°C. Budući da je građa žile slojevita (a u ovom radu se razmatra kao jedan sloj), ne može se točno definirati smjer vlakana koja preuzimaju veći dio opterećenja.


U skladu s time, a s obzirom na smjer opterećenja označena su dva glavna smjera vlakana (slika 32.). Aksijalni smjer označen s A odnosi se na smjer uzduž žile (tj. paralelno sa smjerom protoka krvi) i transverzalni T (okomito na smjer protoka krvi).

U literaturi [11] smjer A označava se s MFD (eng. *Mean Fiber Direction* ili glavni smjer vlakana), a smjer T označen je s CFD (eng. *Cross Fiber Direction* ili poprečni smjer vlakana).




Slika 32. Uzorak svinjske aorte

Važno je napomenuti da se prije prihvaćanja pripremljenog uzorka na ispitni uređaj vodilo računa o njihovoj orijentaciji obzirom na smjer vlaka. Naime, budući da se radi o nehomogenom i anizotropnom materijalu, pretpostavka je da će orijentacija uzoraka tj. vlakana u tkivu utjecati na dobivene rezultate. Time je ostavljena mogućnost usporedbe i kritičkog razmatranja, tj. potencijalnog odgovora na pitanje koliko orijentacija utječe na mehanički odziv mekog tkiva. Svaki uzorak je označen nakon izrezivanja, redom: AORTA1, AORTA2, AORTA3 i AORTA4. Aksijalni smjer uzoraka AORTE 1, 2 i 4 kolinearan je s linearnim aktuatorima 1 i 2 (slika 33.):



Slika 33. Orijentacija uzoraka AORTA 1, 2 i 4

Uzdužni smjer vlakana AORTE 3 je u odnosu na prethodne uzorke zarotiran za 90° , tj. aktuatori 3 i 4 paralelni su s aksijalnom osi svinjske aorte prema slici 34.




Slika 34. Orijentacija uzorka AORTA 3

Sljedeći korak je priprema uzorka za primjenu dvije mjerne metode. Prvotno je definirana zona interesa veličine 10×10 mm i na njenim rubovima zalijepljena su četiri spužvasta markera koja su praćena videoekstenzometrom. Nakon toga slijedilo je nanošenje rastera potrebnog za primjenu metode korelacije digitalne slike. Raster predstavljaju fino raspršene točkice kontrastne boje koju je potrebno nanijeti jer je postojeća površina uzorka jednolične bijele boje. U ovom slučaju je na svijetlu podlogu uzoraka nanesen stohastički taman raster (crna mat nereflektirajuća boja u spreju). Korištena je brzосуšiva boja, te su uzorci bili podvrgnuti sobnoj temperaturi svega nekoliko minuta pa se taj utjecaj na uzorke može zanemariti. Raster tijekom opterećivanja prati promjene oblika mjerne površine, tj. njezine pomake i deformacije. Tako tretirana površina uzoraka pogodna je za provedbu ispitivanja.

Kod tretiranja ispitnih uzoraka bojom vrlo je bitno da se ona dobro poveže s površinom kako ne bi došlo do odvajanja boje od uzorka. U tom slučaju izmjereni pomaci i deformacije ne bi odgovarali onima na mjernoj površini žile.

Od 4 uzorka, tri su tretirana rasterom samo u centru (kvadrat dimenzija 10×10 mm). Četvrti uzorak je tretiran u cijelosti, kako bi se pratile deformacije po cijeloj površini (slika 35.).



Slika 35. Primjeri rastera na uzorcima: a) uzorci AORTA1, 2 i 3, b) uzorak AORTA4

Debljine uzoraka izmjerene su nakon pripreme te navedene u tablici 2. Debljine su mjerene digitalnom pomičnom mjerkom, na sredini svakog od uzorka.

Tablica 2. Debljine uzoraka


UZORCI	AORTA 1	AORTA 2	AORTA 3	AORTA 4
Debljina uzorka t, mm	2,44	2,6	1,83	2,08

7.3. Provedba dvoosnog vlačnog ispitivanja


Nakon pripreme ispitnih uzoraka uslijedilo je mehaničko ispitivanje. Uzorci su pozicionirani na uređaj za opterećivanje prema prethodno opisanom postupku. Eksperimentalni postav korišten kod ispitivanja svih uzoraka prikazan je na slici 36. Osnovne komponente su

1. laboratorijski stol,
2. specijalna kadica s grijačima,
3. digitalna kamera,
4. osvjetljenje,
5. sustav za opterećivanje,
6. upravljačka ploča,
7. računalo,
8. staklo za izbjegavanje stvaranja valova na površini uslijed opterećivanja.

Tijekom ispitivanja uzorci su potopljani u fosfatom puferiranu otopinu soli (eng. *Phosphate Buffered Saline*, PBS), a temperatura otopine bila je oko 37°C (temperatura tijela čovjeka). Tako su se simulirali normalni fiziološki uvjeti. Na slici 37. prikazan je postav s uzorkom, pripremljen za početak mjerenja.




Slika 36. Eksperimentalni postav



Slika 37. Uzorak postavljen na stroj i potopljen u PBS otopinu

7.3.1. Podešavanje i kalibracija sustava

Prije početka mjerenja potrebno je podesiti optički sustav, što podrazumijeva udaljenost sustava od mjernog objekta, osvjetljenje objekta i kalibraciju kamere. Kalibracija služi kako bi se podesili unutarnji i vanjski parametri kamere, te da bi se poništile sve nepravilnosti u kameri koje mogu biti uzrokovane okolinom u kojoj se provodi mjerenje. Primjerice, to može biti prašina, prepreke između mjernog objekta i kamere (staklo ili tekućina), greške i nepravilnosti na lećama itd. Ovisno o promatranoj skali provodi se kalibracija pomoću odgovarajućih kalibracijskih objekata. U ovom radu korištena je pločica koja ima iscrtanu mrežu kvadratića čije su dimenzije (udaljenosti između vrhova/linija) točno određene. Kalibracijski objekt (slika 38.) postavlja se na uzorak i zabilježi se nekoliko fotografija te se na temelju toga određuje kolika je veličina jednog piksela. Na promatranoj mjernoj površini dobiveno je da udaljenost od 1 mm odgovara vrijednosti od 43 piksela tj. $1 \text{ piksel} = 0,02326 \text{ mm}$.



Slika 38. Kalibracija mjernog sustava

7.3.2. Mehaničko ispitivanje


Nakon pripreme i postavljanja uzoraka na dvoosni ispitni uređaj uslijedilo je mehaničko ispitivanje koje je podijeljeno u četiri faze. Eksperimenti su provedeni s kontrolom pomaka, a brzina ispitivanja je bila konstantna za sve uzorke i iznosila je $v = 4 \text{ mm/min}$.

Faze ispitivanja su sljedeće:


1. *prekondicioniranje 1* (P1),
2. *test 1* (T1),
3. *prekondicioniranje 2* (P2),
4. *test 2* (T2).

Faze prekondicioniranja (slika 39. i slika 40.) podrazumijevaju uzastopno opterećivanje i rasterećivanje uzoraka kroz 5 ciklusa kako bi se vlakna tkiva pravilno usmjerila. Time se također osigurava da sva vlakna sudjeluju u prijenosu opterećenja. Ovakva procedura provedbe eksperimenta kod koje prethodi prekondicioniranje uzoraka uvriježen je postupak kod ispitivanja bioloških tkiva [13], [11] i [14]. U ovom radu korišten je protokol kontroliranog vlačnog opterećenja u aksijalnom i transverzalnom smjeru u omjeru 1:1. To znači da se uzorak rastezao jednakim intenzitetom pomaka u oba smjera kroz svih 5 ciklusa.

Nakon toga proveden je *Test1* koji odgovara jednom ciklusu prethodno narinutog prekondicioniranja. Na slikama 39. i 40. prikazan je protokol narinutog programa opterećenja za dva stanja naprezanja. Maksimalna sila kod faza *Prekondicioniranje 1* i *Test 1* označena je s F_{max1} (slika 39.), a kod faza *Prekondicioniranje 2* i *Test 2* vrijednost s F_{max2} (slika 40.). Prema slici 40. vidljivo je da je drugi test proveden s većim opterećenjem (tj. $F_{max2} > F_{max1}$).



Slika 39. a) *Prekondicioniranje 1*, b) *Test 1*



Slika 40. a) *Prekondicioniranje 2*, b) *Test 2*

Kako bi rezultati dobiveni na sva četiri uzorka bili usporedivi određeno je maksimalno dopušteno naprezanje za sve slučajeve. Naime za prvi dio ispitivanja (tj. *Prekondicioniranje 1* i *Test 1*) odabrano maksimalno opterećenje iznosilo je $\sigma_{\max 1} = 0,050 \text{ N/mm}^2$, a za drugi dio (tj. *Prekondicioniranje 2* i *Test 2*) $\sigma_{\max 2} = 0,125 \text{ N/mm}^2$. Budući da su uzorci različitih debljina bilo je potrebno normalizirati granično opterećenje. Normalizacija je provedena tako da se maksimalno narinuto opterećenje pomnožilo s površinom koja iznosi $A = lt$, tj.

$$\sigma_{\max} = F_{\max} / A \rightarrow F_{\max} = \sigma_{\max} A, \quad (32)$$

gdje je t debljina uzorka a l je veličina kvadratnog presjeka promatrane zone interesa ($l \times l$). Iz jednadžbe (32) vidljivo je da normalizacija odgovara izrazu za *Cauchy*evu naprezanje.

Dobivene vrijednosti maksimalnih sila (tj. $F_{\max 1}$ i $F_{\max 2}$) za četiri ispitna uzorka navedene su u tablici 3. Tijekom ispitivanja kada jedan od aktuatora dosegne vrijednost maksimalne sile faza opterećivanja se prekida te se uzorak rasterećuje.

Tablica 3. Vrijednosti maksimalnih sila

UZORCI	AORTA 1	AORTA 2	AORTA 3	AORTA 4
$F_{\max 1}$, N	1,22	1,3	0,915	1,04
$F_{\max 2}$, N	3,05	3,25	2,2875	2,6

7.3.3. Određivanje mjerne nesigurnosti

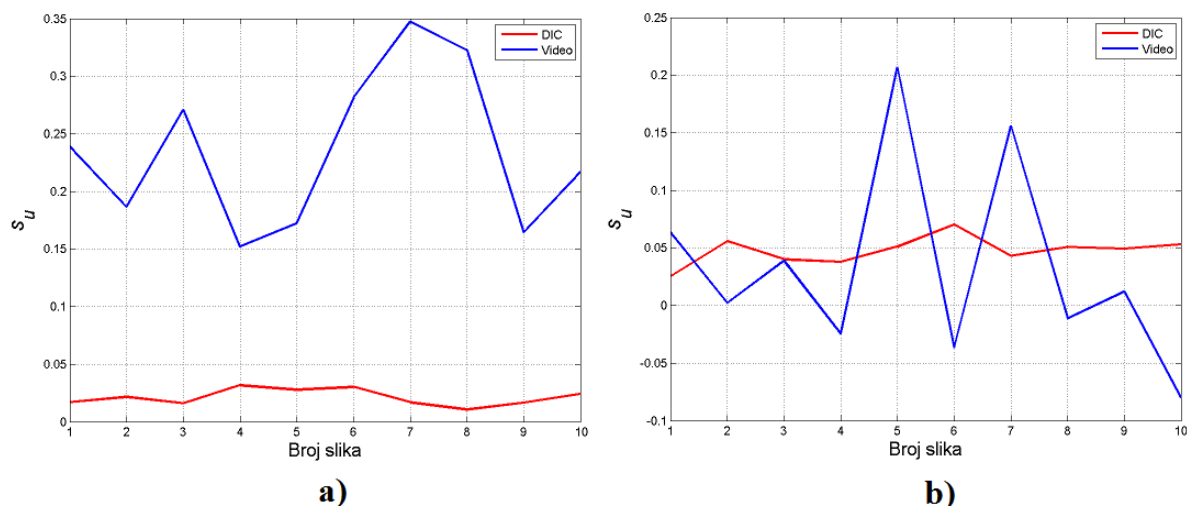
Sva mjerenja podliježu određenim pogreškama koje uzrokuju da se mjerni rezultat razlikuje od prave vrijednosti mjerene veličine. U tom smislu, svaki mjereni rezultat daje se s određenom pouzdanosti. Iz tog razloga, prije i nakon svake faze ispitivanja uslikano je deset slika u trenutku kada je uzorak učvršćen na ispitni uređaj. Kako bi se odredila mjerna pogreška obje optičke mjerne metode (tj. videoekstenzometar i RT3-DIC algoritam) na uzorak nije narinuto opterećenje (tj. $F=0$). Iz slika zabilježenih u neopterećenom stanju izmjereni su pomaci i deformacije. Videoekstenzometrom su dobiveni 1D podaci za mjerene pomake i deformacije za svaku digitalnu sliku koji odgovaraju mjernoj nesigurnosti (slika 41.) budući da bi pomak/deformacija trebala biti jednaka nuli. RT3-DIC određuje pomake za više stupnjeva slobode (n_{DOF}) ovisno o definiranoj zoni interesa i veličini elementa (n_{el}). Ukupna mjerna nesigurnost pomaka i deformacija određena je za cijelu seriju slika prema izrazima

$$s_u^j = \sqrt{\frac{1}{\tilde{n}n_{DOF}} \sum_{i=1}^{\tilde{n}} (\mathbf{u}_i^{meas_j} - \bar{\mathbf{u}}_i^{meas_j})^2}, \quad (33)$$

$$s_\varepsilon^j = \sqrt{\frac{1}{\tilde{n}n_{el}} \sum_{i=1}^{\tilde{n}} (\boldsymbol{\varepsilon}_i^{meas_j} - \bar{\boldsymbol{\varepsilon}}_i^{meas_j})^2}, \quad (34)$$


gdje je \tilde{n} broj slika uzetih u obzir, j je smjer vlakana (tj. aksijalni ili transverzalni smjer), \mathbf{u}_i^{meas} je vektor koji sadrži sve mjerene pomake, $\boldsymbol{\varepsilon}_i^{meas}$ je vektor koji sadrži sve mjerene deformacije, a $\bar{\bullet}$ označava srednju vrijednost. n_{DOF} i n_{el} za mjerenje videoekstenzometrom iznosi jedan budući da se radi o 1D mjerenju.

Na slikama 41. i 42. nalaze se usporedni prikazi mjerne pogreške dobivene za dvije mjerne metode u aksijalnom i transverzalnom smjeru. Razmatran je uzorak AORTA1, a evolucija mjerne nesigurnosti prezentirana je tako da su uzete u obzir sve slike zabilježene u neopterećenom stanju. Iz dobivenih rezultata vidljivo je da se DIC algoritmom dobivaju manje vrijednosti standardne rezolucije pomaka i deformacija⁹. Štoviše, standardna rezolucija pomaka i deformacija metode korelacije digitalne slike rezultira manjim fluktuacijama (tj. mjerna rezolucija je skoro konstantna kroz slike zabilježene u neopterećenom stanju) nego što je zabilježeno kod mjerenja s videoekstenzometrom.



Slika 41. Usporedni prikaz standardnog odstupanja pomaka u za uzorak AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar

⁹ Odnosi se na nominalnu ili inženjersku deformaciju (eng. „nominal“ ili „engineering strain“), u daljnjem tekstu.



Slika 42. Usporedni prikaz standardnog odstupanja deformacije ε za uzorak AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar

U tablici 4. prikazane su prosječne vrijednosti standardnog odstupanja pomaka i deformacija u aksijalnom i transverzalnom smjeru za videoekstenzometar i DIC metodu.

Tablica 4. Prosječne vrijednosti standardnog odstupanja pomaka i deformacija u smjeru osi A i T za AORTU 1 za videoekstenzometar i DIC

	s_u^A	s_u^T	s_ε^A	s_ε^T
Videoekstenzometar	0,0685	0,0885	$1,6404 \times 10^{-4}$	$2,2032 \times 10^{-4}$
DIC	0,0070	0,0121	$0,49847 \times 10^{-4}$	$0,64598 \times 10^{-4}$

Može se primijetiti da je prosječna vrijednost standardnog odstupanja pomaka u aksijalnom smjeru s_u^A za videoekstenzometar gotovo jedan red veličine veća od one dobivene za DIC metodu. Razlika u vrijednostima standardnog odstupanja pomaka u transverzalnom smjeru s_u^T je nešto manja te je oko 7 puta veća kod videoekstenzometra u odnosu na DIC. Isti trend vidljiv je kod ukupne vrijednosti standardnog odstupanja deformacije s_ε^A i s_ε^T . U ovom slučaju omjeri su sličniji te su kod videoekstenzometra vrijednosti navedenih veličina u oba smjera nešto više od 3 puta veće nego kod DIC metode.

Iz prikazanih dijagrama i tablice može se vidjeti da DIC metoda ima znatno manje standardno odstupanje pomaka i deformacija u odnosu na videoekstenzometar. Naravno, to je bilo i za očekivati, budući da videoekstenzometar prati pomake u samo dvije točke, a DIC analizira cijelo polje pomaka, kako je već prethodno objašnjeno. Stoga se može zaključiti da DIC metoda daje pouzdanije rezultate u odnosu na videoekstenzometar.

8. REZULTATI

U ovom poglavlju prikazani su rezultati analize ispitnog uzorka AORTA 1. Rezultati su prikazani prema redoslijedu faza ispitivanja. Za svaku fazu ispitivanja redom su prikazani sljedeći dijagrami

- Usporedni prikazi promjene deformacija mjerenih RT3-DIC algoritmom i videoekstenzometrom u periodu opterećenja i rasterećenja za aksijalni i transverzalni smjer.
- Ovisnost narinute sile F i izmjernih deformacija ε u smjeru vlakana i okomito na njih. Vrijednosti deformacije izmjerenih RT3-DIC metodom korišteni su za prikaz rezultata budući da je kod nje zabilježena manja standardna rezolucija pomaka/deformacija.
- Usporedni prikazi promjene deformacija ε u aksijalnom (ε_{11}) i transverzalnom smjeru (ε_{22}) te posmične deformacije (ε_{12}) izmjerenih metodom korelacije digitalnih slika.
- Promjena sila F_{1-2} i F_{3-4} u dva međusobno okomita smjera opterećenja. Sile za dva pravca opterećenja definirane su kao srednja vrijednost sila izmjerenih na dva senzora sile koji se nalaze u istoj osi.


Za svaku fazu eksperimentalnog ispitivanja prikazana su polja pomaka i deformacija izmjerenih RT3-DIC metodom. Izmjerene fluktuacije deformacija dani su za maksimalna opterećenja. Za ispitni uzorak AORTA1 prezentirana su polja deformacija kako bi se procijenio utjecaj prihvata (tj. udica). Na kraju ovog poglavlja dana je diskusija koja uključuje sveobuhvatni osvrt na analizirane eksperimentalne rezultate. Za preostala tri ispitna uzorka (AORTA2-3-4) rezultati su dani u prilogu.

8.1. Eksperimentalni rezultati za ispitni uzorak AORTA 1

1. Prekondicioniranje 1 (P1)


Prva faza ispitivanja obuhvaća 5 ciklusa opterećenja do maksimalne sile F_{max1} i rasterećenja do sile jednake nuli. Na slici 43. prikazana je promjene deformacije ε u aksijalnom i transverzalnom smjeru za dvije primijenjene optičke metode. Za uzdužni smjer orijentacije vlakana (slika 43. a) vidljivo je da postoje određena odstupanja maksimalnih deformacija koja se kreću od 0,5 do 2%. Deformacije izmjerene DIC metodom rezultiraju višim vrijednostima u odnosu na videoekstenzometar dok u fazi rasterećenja taj efekt nije zabilježen.

Izmjerene DIC deformacije u transversalnom smjeru (slika 43. b) pokazuju odstupanja u fazi opterećenja i raterćenja. U cijelom vremenskom periodu ispitivanja od 290 sekundi može se zaključiti da postoji pomak između krivulja izmjerenih optičkim mjernim metodama.




Slika 43. Usporedni prikaz promjene deformacije ε u vremenu t za *Prekondicioniranje 1* uzorka AORTA 1 u a) aksijalnom (A) i b) transversalnom (T) smjeru za DIC i videoekstenzometar

Na slici 44. prikazane su srednje vrijednosti mjerenih sila između dva aktuatora u istoj osi opterećivanja, tj. za prvih pet ciklusa prvog prekondicioniranja dane su vrijednosti sila u aksijalnom i transversalnom smjeru. Vidljivo je da se vršne vrijednosti sile u aksijalnom i transversalnom smjeru razlikuju. Tijekom svih ciklusa opterećenja zabilježena je za 0,1 N veća sila u smjeru vlakana. S obzirom na prezentirane rezultate na slici 44. može se zaključiti da je prvo u aksijalnom smjeru sila dosegla maksimalnu vrijednost F_{max1} te je period opterećivanja prekinut.




Slika 44. Dijagram promjene sile F za *Prekondicioniranje 1* uzorka AORTA 1 u aksijalnom (A) i transversalnom (T) smjeru

Kako bi se usporedile vrijednosti deformacija izmjerenih RT3-DIC algoritmom u aksijalnom i transversalnom smjeru dan je njihov usporedni prikaz na slici 45. Vidljivo je da su u ovom slučaju deformacije u aksijalnom smjeru (ε_{11}) neznatno veće od deformacija u transversalnom smjeru (ε_{22}). Prikazane su i posmične deformacije kako bi se pokazalo da se i one pojavljuju. Vrijednosti posmičnih deformacija (ε_{12}) su zanemarive (manje od 1 %) što je i za očekivati budući da se radi o ravninskom dvoosnom ispitivanju sa ekvibiaksialnim uvjetima opterećenja.



Slika 45. Usporedni prikaz promjene deformacija ε za *Prekondicioniranje 1* uzorka AORTA 1


Ovisnost izmjerenih sile i deformacija u dva međusobno okomita smjera opterećenja prikazana je na slici 46. Za ove dijagrame korištene su vrijednosti deformacija dobivene DIC metodom. U oba smjera zabilježeno je da se periodi opterećenja i rasterećenja ne poklapaju već se pojavljuju blage histereze. Vidljivo je da se vrijednosti deformacija u oba smjera kreću oko 10 % što je bilo i za očekivati s obzirom da je srednja vrijednost sile u aksijalnom smjeru opterećenja prije dosegla vrijednost sile F_{max1} . Također, pažljivim promatranjem može se primjetiti da se s brojem ciklusa za istu vrijednost sile povećava vrijednost deformacije.



Slika 46. Dijagram sila F – deformacija ε za Prekondicioniranje 1 uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru

U nastavku su dane izmjerene fluktuacije polja deformacija za vršne vrijednosti opterećenja u aksijalnom i transverzalnom smjeru (slika 47.). Izmjereno polje pomaka za maksimalno opterećenje u prvom ciklusu rezultira najmanjim utjecajem prihvata (tj. udica). U svakom sljedećem trokutastom ciklusu povećava se lokalizacija na rubovima promatrane zone interesa. U aksijalnom smjeru (tj. ε_{11}) vidljiva je horizontalna traka u donjem dijelu polja deformacija čiji se intenzitet povećava s brojem narinutih ciklusa. U gornjem dijelu polja deformacija između 200 i 300 piksela zabilježeno je homogeno polje pomaka s vrijednostima oko 10% što odgovara deformacijama mjerenim virtualnom mjernom trakom (slika 46.). Najveći utjecaj kukica kod ε_{11} polja deformacija zabilježen je na donjem horizontalnom rubu. Središnji dio polja deformacija u transverzalnom smjeru (tj. ε_{22}) ima homogenu raspodjelu deformacija. Vrijednosti deformacija u tom dijelu između 300 i 400 piksela imaju vrijednost od 11% dok su u ostalim dijelovima izmjerene manje vrijednosti.


U smjeru okomito na smjer vlakana polja deformacija rezultiraju lokalizacijom uslijed utjecaja prihvata na vertikalnim rubovima. Osim toga, jak utjecaj udica zabilježen je i na donjem, horizontalnom rubu. Uslijed povećanja broja ciklusa povećava se i nehomogenost polja deformacija na rubovima ispitnog uzorka. Također je uočeno i suženje središnjeg homogenog dijela, na kojem se povećavaju vrijednosti deformacija ε_{22} .



Slika 47. Mjerena polja deformacija za vršne vrijednosti opterećenja za Prekondicioniranje 1 uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru


2. *Test 1 (T1)*

Druga faza ispitivanja obuhvaća jedan ciklus opterećenja do sile F_{max1} te rasterećenje (tj. $F=0$). Slijedi usporedni prikaz promjene izmjerenih deformacija u aksijalnom i transversalnom smjeru za primijenjene optičke metode (slika 48.). Deformacije dobivene DIC metodom su u oba smjera nešto veće od 10% te su približno jednake, dok su one izmjerene videoekstenzometrom u aksijalnom smjeru manje od 10%, a u transversalnom oko 11%. Trajanje ispitivanja kod ove faze je nešto dulje od 60 sekundi. Obje optičke metode opisuju približno iste trendove no ipak je moguće uočiti kako su rezultati dobiveni DIC metodom ujednačeniji ako se uspoređi odziv materijala u oba smjera opterećivanja.




Slika 48. Usporedni prikaz promjene deformacije ε u vremenu t za *Test 1* uzorka AORTA 1 u a) aksijalnom (A) i b) transversalnom (T) smjeru za DIC i videoekstenzometar

Na slici 49. uspoređene su za *Test 1* srednje vrijednosti sila u aksijalnom i transverzalnom smjeru. Kao i u prethodnoj fazi, postoji razlika u vršnoj vrijednosti sila za dva smjera koja iznosi 0,15 N. U ovoj fazi eksperimentalnog ispitivanja sila u smjeru vlaka (tj. aksijalnom smjeru) prva dostiže vrijednost F_{max1} . Isti trend je zabilježen i kod *Prekondicioniranja 1*.




Slika 49. Dijagram promjene sile F za *Test 1* uzorka AORTA 1 u aksijalnom (A) i transverzalnom (T) smjeru

Nadalje, slijedi prikaz evolucije deformacija u aksijalnom (ε_{11}) i transverzalnom (ε_{22}) smjeru (slika 50.). Vidljivo je da su vrijednosti deformacija u oba smjera nešto više od 10% te da je ona u transverzalnom smjeru neznatno veća. Deformacije izmjerene u oba smjera opterećenja pokazuju bolje poklapanje nego što je zabilježeno za *Prekondicioniranje 1*. Vrijednosti posmične deformacije (ε_{12}) su zanemarivo male u usporedbi s ε_{11} i ε_{22} što je i za očekivati budući se radi o ekvibiaksijalnom ispitivanju.



Slika 50. Usporedni prikaz promjene deformacija ε za *Test 1* uzorka AORTA 1


U nastavku su dani F – ε dijagrami za fazu *Test 1* u aksijalnom i transverzalnom smjeru (slika 51). Kao i u prethodnoj fazi, vidi se utjecaj histereze u oba smjera (tj. nije zabilježen elastični povrat s obzirom na fazu opterećenja). Vrijednosti deformacija su približno jednake s onima zabilježenim u fazi *Prekondicioniranje 1*.




Slika 51. Dijagram sila F – deformacija ε za *Test 1* uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru

Na slici 52. prikazana su mjerena polja pomaka u aksijalnom i transverzalnom smjeru za vršne vrijednosti opterećenja kod faze *Test 1*. Izmjerena polja pomaka metodom korelacije digitalne slike su glatka i na njima nije zabilježen lokalizacijski utjecaj prihvata (tj. udica).

Promatrajući izmjerena Green-Lagrangeova polja deformacija na slici 53. koja odgovaraju poljima pomaka na slici 52. zabilježena je nehomogenost koja se može objasniti upotrebom nedovoljnog broja udica na rubu ispitnog uzorka. Na polju deformacija u aksijalnom smjeru zabilježena je lokalizacija na horizontalnim rubovima promatrane zone. Isti trend je uočen i na vertikalnim rubovima kod transverzalnog polja deformacija. Lokalizacija je u smjeru okomitom na smjer vlakana zabilježena i na donjem horizontalnom rubu. Na središnjem dijelu ispitnog uzorka dimenzija 150x150 piksela izmjereno je homogeno polje pomaka koje bi trebalo uzeti u obzir prilikom identifikacije parametara materijala hiperelastičnih konstitutivnih zakona. Marker koji koristi videoekstenzometar za mjerenje deformacija smješteni su na rubu promatrane zone. Stoga je utjecaj udica veći što uzrokuje razliku između izmjerenih deformacija s RT3-DIC algoritmom. Prosječne deformacije u promatranoj zoni interesa DIC metoda određuje linearnom regresijom odabranog dijela polja pomaka.




Slika 52. Mjerena polja pomaka za vršnu vrijednost opterećenja za *Test 1* uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnog (T) smjeru



Slika 53. Mjerena polja deformacija za vršnu vrijednost opterećenja za *Test 1* uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnog (T) smjeru


3. Prekondicioniranje 2 (P2)

Treća faza ispitivanja obuhvaća 5 trokutastih ciklusa opterećenja do maksimalne sile F_{max2} i rasterećenja (tj. $F=0$). Usporedni prikaz promjene deformacije ε u vremenu t u aksijalnom i transverzalnom smjeru za dvije korištene metode dan je na slici 54. Maksimalne vrijednosti deformacija dobivene DIC metodom u oba smjera pokazuju veće vrijednosti od onih izmjerenih videoekstenzometrom. Za DIC se kreću oko 21-22%, a za videoekstenzometar oko 18-19%. U fazi rasterećenja obje metode registriraju približno jednak razine deformacija te je vidljivo dobro poklapanje. Vrijeme trajanja *Prekondicioniranja 2* ove faze ispitivanja trajalo je oko 590 sekundi što je približno dva puta duže od *Prekondicioniranja 1*.




Slika 54. Usporedni prikaz promjene deformacije ε u vremenu t za *Prekondicioniranje 2* uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar

Vrijednosti sila za *Prekondicioniranje 2* u aksijalnom i transverzalnom smjeru prikazane su na slici 55. Kao i u prethodne dvije faze eksperimentalnog ispitivanja vidljiva je mala razlika u maksimalnim vrijednostima sila (F_{max1}) tj. sila u aksijalnom smjeru veća je za 0,1 N od one u transverzalnom smjeru.




Slika 55. Dijagram promjene sile F za *Prekondicioniranje 2* uzorka AORTA 1 u aksijalnom (A) i transverzalnom (T) smjeru

Kod ove faze ispitivanja deformacija izmjerena u transverzalnom smjeru veća je od one zabilježene u aksijalnom smjeru što nije u skladu s *Prekondicioniranjem 1*. Na slici 56. prikazan je dijagram na kojem je dan usporedni prikaz deformacija u aksijalnom (ε_{11}) i transverzalnom (ε_{22}) smjeru te posmične deformacije (ε_{12}). Deformacije u oba smjera se prilično dobro poklapaju, uz razliku da se deformacija u transverzalnom smjeru malo povećava kako se povećava broj ciklusa. Vrijednosti deformacija ε_{11} i ε_{22} su nešto više od 20%. Posmične deformacije su kao i kod prethodnih faza, gotovo zanemarive te se ne povećavaju iako je $F_{max2} > F_{max1}$.



Slika 56. Usporedni prikaz promjene deformacija ε za *Prekondicioniranje 2* uzorka AORTA 1

Na slici 57. prikazani su F – ε dijagrami za fazu *Prekondicioniranje 2* u aksijalnom i transverzalnom smjeru. Deformacije u oba smjera su malo veće od 20 %. Može se primjetiti da su u transverzalnom smjeru gotovo nezamjetno veće (oko 1%) u usporedbi s aksijalnim smjerom. U odnosu na fazu *Prekondicioniranje 1* vidljivo je da je utjecaj histereza manji, tj. prostor između krivulja opterećenja i rasterećenja je uži. Razlog tomu je „namještanje“ vlakana tkiva uslijed opterećenja. Kako faze idu dalje, vlakna se sve više „namještaju“ i histereze su manje. Iz ovoga se može zaključiti da je moguće nariniti i manje od pet ciklusa za *Prekondicioniranje 2*.




Slika 57. Dijagram sila F – deformacija ε za *Prekondicioniranje 2* uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru

Kako bi se dobio uvid u raspodjelu deformacija tijekom faze ispitivanja *Prekondicioniranje 2* na slici 58. prezentirana su polja Green-Lagrangeovih deformacija izmjerena pomoću RT3-DIC algoritma. Na lijevoj strani slike prikazan je odziv materijala u aksijalnom smjeru (tj. ε_{11} deformacije) a na desnoj strani u transverzalnom smjeru (tj. ε_{22} deformacije). Slika 58. se sastoji od pet redova koji odgovaraju broju narinutih ciklusa.

Kao i u prvoj fazi eksperimentalnog ispitivanja (tj. *Prekondicioniranje 1*) zabilježeno je povećanje lokalizacijskog utjecaja udica na rubovima promatrane zone. Maksimalne vrijednosti deformacija su upravo na rubovima te one iznose više od 40%. U središnjem dijelu raspodjela deformacija obuhvaća veću homogenu zonu nego što je vidljivo kod *Prekondicioniranja 1*.


Izmjerene vrijednosti deformacija u središnjem dijelu iznose 22%. Može se primijetiti da su vrijednosti homogene zone deformacije više od prosječnih deformacija određenih optičkom mjernom trakom. Budući da je za mjerenje prosječnih deformacija uzeta u obzir cijela promatrana zona, vrijednosti su niže od onih zabilježenih na poljima deformacija u aksijalnom i transverzalnom smjeru.



Slika 58. Mjerena polja deformacija za vršne vrijednosti opterećenja za *Prekondicioniranje 2* uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru


4. Test 2 (T2)

Četvrta faza ispitivanja obuhvaća jedan ciklus trokutastog opterećenja do granične sile F_{max2} i rasterećenja. Na slici 59. prikazana je usporedba promjene deformacija u aksijalnom i transverzalnom smjeru za videoekstenzometar i metodu korelacije digitalne slike. Vršne vrijednosti deformacija dobivene DIC metodom kod maksimalnog opterećenja u oba smjera su veće od onih dobivenih videoekstenzometrom. Za DIC se kreću oko 21-22%, a za videoekstenzometar oko 18-19%. Isti trend je zabilježen i kod prethodne faze ispitivanja.




Slika 59. Usporedni prikaz promjene deformacije ϵ u vremenu t za *Test 2* uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar

Dijagram vrijednosti sila za fazu *Test 2* u aksijalnom i transverzalnom smjeru prikazan je na slici 60. Kao i u prethodnoj fazi, postoji razlika u vršnoj vrijednosti sila za dva smjera koja iznosi oko 0,1 N. Sila u aksijalnom smjeru prva dostiže vrijednost F_{max2} nakon čega se prekida režim opterećivanja.



Slika 60. Dijagram promjene sile F za *Test 2* uzorka AORTA 1 u aksijalnom (A) i transverzalnom (T) smjeru


Nadalje, slijedi usporedni prikaz promjene deformacija u aksijalnom (ε_{11}) i transverzalnom (ε_{22}) smjeru, te posmične deformacije (ε_{12}), (slika 61.). Vidljivo je da je vrijednost deformacije u oba smjera nešto više od 20% te da je ona u transverzalnom smjeru neznatno veća. Kao i u prethodnim fazama, posmična deformacija postoji, no njezina je vrijednost vrlo mala i može se zanemariti.



Slika 61. Usporedni prikaz promjene deformacija ε za *Test 2* uzorka AORTA 1


Na slici 62. prezentirani su F – ε dijagrami za fazu *Test 2* u smjeru vlakana i okomito na njih. Utjecaj histereze je opet vidljiv u oba smjera, ali je znatno manji nego kod faze *Test 1* zato što je na ispitni uzorak već narinuto jedanaest ciklusa.

S obzirom na njih biloški materijal je prošao kroz „namještanja“ vlakana kod faza *Prekondicioniranje 1*, *Test 1* i *Prekondicioniranje 2*.



Slika 62. Dijagram sila F – deformacija ε za *Test 2* uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru


Polja pomaka mjerena RT3-DIC algoritmom za vršne vrijednosti opterećenja kod faze *Test 2* prikazana su na slici 63. Vrijednosti fluktuacija izmjerenih u posljednjoj fazi eksperimentalnog ispitivanja dva puta su veće nego kod *Testa 1*. Utjecaj udica koje su natakute na rubu ispitnog uzorka AORTA 1 nije zabilježen.



Slika 63. Mjerena polja pomaka za vršnu vrijednost opterećenja za *Test 2* uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru

Utjecaj prihvata na biološkom mekom tkivu zabilježen je na poljima deformacija u aksijalnom (slika 63. a) i transverzalnom smjeru (slika 63. b). Horizontalni rubovi na polju deformacija u smjeru vlakana registriraju lokalizaciju uslijed nedovoljnog broja udica.


Na donjem horizontalnom rubu zabilježen je veći diskontinuitet s obzirom na homogeni središnji dio ispitnog uzorka. Fluktuacije izmjerene u okomitom smjeru vlakana rezultiraju lokalizacijom na vertikalnim rubovima te na donjem horizontalnom rubu. U usporedbi sa Green-Langrangeovim deformacijama mjerenim u *Testu 1* zona homogenog polja je veća kod $F_{max2} > F_{max1}$ i iznosi 300x200 piksela.



Slika 64. Mjerena polja deformacija za vršnu vrijednost opterećenja za *Test 2* uzorka AORTA 1 u a) aksijalnom (A) i b) transverzalnom (T) smjeru

8.2. Usporedba rezultata uzoraka AORTA 1, AORTA 2 i AORTA 3

Kako bi se lakše usporedilo mehaničko ponašanje tkiva pojedinih uzoraka prikazan je odnos naprezanja i deformacija za prva tri ispitna uzorka. Uzorak AORTA 4 ovdje nije uzet u obzir jer je analizirana veća zona interesa s ciljem određivanja utjecaja prihvata na polje deformacija. Na slici 65. prikazan je σ - ϵ dijagram opterećenja eksperimentalne faze *Test 1* za tri uzorka. Indeksi A i T uz nazive uzoraka predstavljaju aksijalni i transverzalni smjer opterećenja.




Slika 65. Dijagrami opterećenja uzoraka AORTA 1, AORTA 2 i AORTA 3 u aksijalnom (A) i transversalnom (T) smjeru

Bitno je primjetiti da sva tri uzorka u aksijalnom smjeru imaju veću krutost u odnosu na transversalni smjer. To znači da je deformacija u transversalnom smjeru veća. Također, vidljivo je da uzorak AORTA 1 pokazuje najmanju razliku između aksijalnog i transversalnog smjera. Najveća razlika je za uzorak AORTA 3. Te razlike upućuju na anizotropnost tkiva. Odstupanja rezultata pokazuju da se anizotropnost pojavljuje u različitom stupnju. Razlog toga može biti u mjestu tkivu s kojeg je uzorak preuzet, debljini uzorka i sl. Naprezanja kod ove faze dostižu vrijednosti 0,050 MPa.

Uzorak AORTA 3 rezultira najvećom krutosti u aksijalnom smjeru. Razlog navedenog odstupanja je debljina uzorka koja je 30% manja nego kod uzoraka AORTA 1 i AORTA 2. Međutim, u transversalnom smjeru za *Test 1* vrijednosti za uzorak AORTA 3 dobro se poklapaju s ispitnim uzorkom AORTA 1. Također važno je napomenuti da je razlika između aksijalnog i transversalnog smjera jednaka za uzorke AORTA 1 i AORTA 3 pri fazama eksperimentalnog ispitivanja *Test 1* (slika 65.) i *Test 2* (slika 66.).

Iz σ - ϵ dijagrama je vidljivo da za opterećenja faze *Test 2* promatrani uzorci (slika 66.) postižu naprezanja od 0,125 MPa. Isti trend je zabilježen i za ovaj dio ispitivanja. Pretpostavlja se da najveći utjecaj na razliku u rezultatima ima neujednačena debljina ispitnih uzoraka, budući da su se za računanje Cauchyevog naprezanja uzimale prosječne vrijednosti.




Slika 66. Dijagrami opterećenja uzoraka AORTA 1, AORTA 2 i AORTA 3 u aksijalnom (A) i transversalnom (T) smjeru


8.3. Utjecaj prihvata na homogenost polja pomaka i deformacija

Na ispitnom uzorku AORTA 4 uzeta je veća promatrana zona interesa (tj. mjereni su pomaci i deformacije na cijelom ispitnom uzorku gdje su granice promatranog područja bile udice). Mreža konačnih elemenata korištena za DIC mjerenje postavljena je neposredno uz mjesta prihvata s ciljem određivanja utjecaja prihvata na izmjereno polje pomaka i deformacija. Iz priloženih mjerenih polja pomaka i deformacija za navedeni uzorak može se primjetiti da postoje lokalizacije na poljima pomaka (slika 67.) i deformacija (slika 68.). Izmjereni pomaci i deformacije u aksijalnom smjeru registriraju utjecaj kukica u blizini horizontalnih rubova promatrane zone interesa. Suprotno tome, u transversalnom smjeru su pod utjecajem lokalizacije vertikalni rubovi. Nepravilne konture pomaka definiraju područje u kojem je utjecaj kukica zanemariv. Veličina homogene zone kod promatranih polja pomaka je u središnjem dijelu uzorka veličine 200x200 piksela.

Izmjerena Green-Lagrangeova polja deformacija pokazuju utjecaj kukica. Po sredini ispitnog uzorka zabilježene su deformacijske trake koje uzrokuju središnje udice. Osim toga na rubovima promatrane zone maksimalne deformacije izmjerene su u blizini središnje udice. Polja pomaka i deformacija potvrđuju rezultat prijašnjeg istraživanja [53] te se može zaključiti da je za postizanje homogenijeg polja pomaka i deformacija potrebno povećati broj kukica kojima se opterećuje biološko meko tkivo.



Slika 67. Mjerena polja pomaka za vršnu vrijednost opterećenja za *Test 2* uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru



Slika 68. Mjerena polja deformacija za vršnu vrijednost opterećenja za *Test 2* uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru

8.4. Diskusija

Na dijagramima koji prikazuju usporedbu deformacija dobivenih s dvije optičke metode – DIC-om i videoekstenzometrom mogu se primijetiti odstupanja u rezultatima što je i za očekivati jer se radi o metodama s različitim standardnim mjernim rezolucijama. Budući da je prethodno pokazano da DIC metoda ima manju mjernu nesigurnost (time je pouzdanija) u daljnjim analizama bile su korištene vrijednosti deformacija dobivene tom metodom. Štoviše, najveći utjecaj na odstupanje prosječnih deformacija uzrokovano je različitim konceptima primjenjenih optičkih metoda. Videoekstenzometrom nisu uzeti u obzir lokalizacijski efekti uzrokovani prihvatima kojima je pričvršćen ispitni uzorak. Praćenjem samo dva markera gube se informacije koje opisuju ponašanje materijala uslijed narinutog opterećenja.

Suprotno tome, DIC metoda pretpostavlja kontinuitet polja pomaka i time je fenomen lokalizacije uslijed nedovoljnog broja prihvata uzet u obzir.

$F-\varepsilon$ dijagrami (u aksijalnom i transverzalnom smjeru) potvrđuju nelinearno ponašanje tkiva uz primjetne histereze tj. nepodudaranje krivulja opterećenja i rasterećenja. Histereze su rezultat viskoelastičnog ponašanja tkiva, koje je posljedica visokog udjela vode u tkivu [14]. Također, prisutno je i omekšavanje tkiva, poznato kao *Mullins-efekt* [11]. To znači da deformacija postaje veća kod svakog sljedećeg ciklusa opterećenja uz iste (ili jako slične) vrijednosti sila, što je i zabilježeno na dijagramima kod ispitne faze *Prekondicioniranje 1* (Slika 46.) i *Prekondicioniranje 2* (Slika 57.).

Nadalje, promatranjem histereza može se primijetiti da se one sužavaju upravo zbog „namještanja“ vlakana tkiva kroz faze prekondicioniranja i pojave *Mullins-efekta*. Kod faze *Prekondicioniranje 1* i *Test 1* maksimalna deformacija uzorka kreće se oko 10%, a kod faze *Prekondicioniranje 2* i *Test 2* duplo je veća i iznosi 20%. Velike deformacije, nelinearan odnos naprezanje (ili sila) – deformacija, anizotropija i histereze karakteriziraju mnoga biološka tkiva. Mehanička ispitivanja provedena na mekim tkivima u literaturi ([6]-[14], [54], [55]) dala su slične rezultate.

Tijekom svake faze ispitivanja sila je mjerena na svakom aktuatoru, a prosječne vrijednosti za aksijalni i transverzalni smjer dobivene su zbrajanjem vrijednosti sila susjednih aktuatora te dijeljenjem te vrijednosti sa 2. To znači za aksijalni smjer vrijedi: $(F_1+F_2)/2$, a za transverzalni smjer je: $(F_3+F_4)/2$. Kao što je opisano u eksperimentu, kada je sila na jednom od aktuatora dosegla maksimalnu vrijednost, opterećivanje je prekinuto te je uzorak jednoliko rasterećen. Zbog toga se u dijagramima promjene sile očituju male razlike u prosječnim vrijednostima sila u aksijalnom i transverzalnom smjeru.

Promatrajući dijagrame svih deformacija (ε_{11} , ε_{22} , ε_{12}) uzorka AORTA 1 može se primijetiti da je samo u fazi *Prekondicioniranje1* deformacija u aksijalnom smjeru (ε_{11}) neznatno veća od deformacije u transverzalnom smjeru (ε_{22}). Kod svih ostalih faza deformacija ε_{22} je veća od ε_{11} . Malo odstupanje kod faze *Prekondicioniranje1* je prisutno jer se vlakna još nisu „namjestila“, no kroz 5 ciklusa primjećuje se tendencija rasta deformacije ε_{22} . Već u sljedećoj fazi opterećivanja (*Test1*) deformacija ε_{22} poprima veće vrijednosti u odnosu na ε_{11} . U sljedećim fazama nastavlja se takav odnos.

Uspoređujući rezultate deformacija svih uzoraka može se primjetiti da se isto ponašanje mekog tkiva očituje i kod preostalih uzoraka uz nešto naglašeniju razliku u vrijednosti deformacija ε_{11} i ε_{22} .

Važno je naglasiti da se tijekom biaksijalnih testova pojavljuju i posmična naprezanja koja se ne mogu kontrolirati tijekom ispitivanja. Mnogi autori ih potpuno zanemaruju, pod pretpostavkom da ona ne postoje (jer su jako mala) no to se ne može uzeti sa sigurnošću [14]. Smicanje se može svesti na minimum i time zanemariti ukoliko se ispitni uzorci pripreme i ispituju na odgovarajući način (prema literaturi [14], [53]) koji je opisan i korišten u ovom radu. Najbitnije je da uzorci budu kvadratičnog oblika, što tanji, pozicionirani tako da smjer glavnih vlakana bude u smjeru opterećenja, te da udice za prihvat budu pravilno raspoređene po rubu uzorka kako bi prijenos opterećenja bio jednolik na svakoj strani. Na prikazanim dijagramima vidljivo je da se vrijednosti posmičnih deformacija (ε_{12}) mogu zanemariti u usporedbi s vrijednostima deformacija ε_{11} i ε_{22} .


Ravninsko dvososno eksperimentalno ispitivanje na četiri ispitna uzorka potvrđuje dosadašnje spoznaje o mehaničkim svojstvima krvnih žila. Iz prikazanih rezultata u ovom poglavlju može se zaključiti da je krutost ispitanog mekog tkiva (tj. svinjske aorte) veća u smjeru protoka krvi.

9. IDENTIFIKACIJA PARAMETARA MATERIJALA ZA HIPERELASTIČNI MATERIJALNI MODEL

9.1. Kalibracija hiperelastičnog materijalnog modela: *neo – Hooke*

Eksperimentalno dostupni podaci o promjeni naprezanja i deformacija uslijed narinutog dvoosnog stanja naprezanja korišteni su za identifikaciju parametara materijala predloženih hiperelastičnih konstitutivnih zakona. Prvo je uzet u obzir najjednostavniji materijalni model *neo – Hooke* za dvoosno stanje naprezanja. C_{10} je parametar koji je potrebno odrediti (slika 69.). Koeficijent D_1 se u analizama ne uzima u obzir jer je vezan za stlačivost materijala (pretpostavljena je nestlačivost biološkog mekog tkiva).

Vidljivo je da hiperelastični model *neo – Hooke* nije prihvatljiv za opisivanje trenda krivulje dobivene iz eksperimentalnih podataka što je i za očekivati budući da se radi o jednostavnoj polinomnoj funkciji s jednim parametrom materijala.




Slika 69. Kalibracija *neo – Hooke* materijalnog modela za dvoosno stanje naprezanja

Identificirani parametar razmatranog dvoosnog stanja naprezanja za *neo–Hooke* materijalni model prikazan je u tablici 5. Uz njega je naveden i koeficijent kalibracije R^2 (tj. koeficijent koji procjenjuje odstupanje eksperimentalne i kalibrirane krivulje ponašanja materijala).

Tablica 5. Parametar materijala i koeficijent $R2$ za *neo – Hooke* materijalni model pri dvoosnom stanja naprezanja

C_{10}	0,0463267
$R2$	0,782

Iako postoji očito odstupanje eksperimenatlna i kalibrirane krivulje (slika 69.) Druckerov kriterij stabilnosti za identificirani materijalni parametar C_{10} zadovoljen je za sva opterećenja u definiranom području $-0.5 \leq \varepsilon \leq 0.5$ (slika 70).




Slika 70. Provjera Druckerovog kriterija stabilnosti za *neo – Hooke* materijalni model

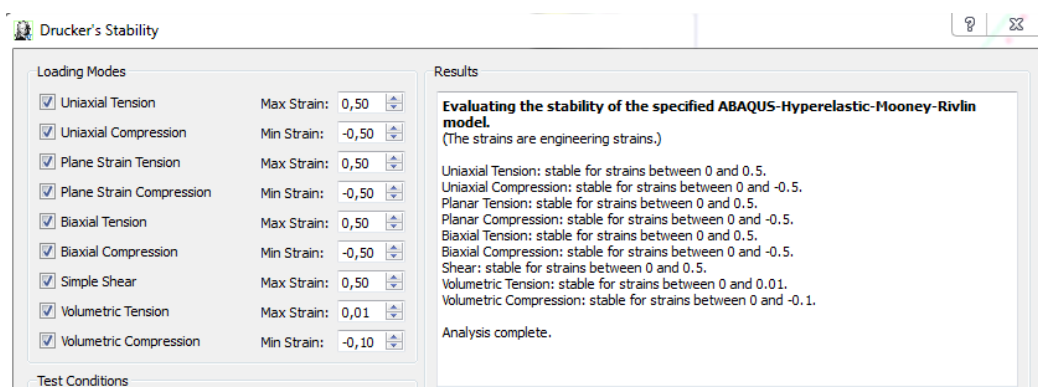
9.2. Kalibracija hiperelastičnog materijalnog modela: *Mooney – Rivlin*

Drugi materijalni model koji je uzet u razmatranje je *Mooney–Rivlin*. Za navedeni konstitutivni zakon potrebno je odrediti iznose parametara materijala C_{10} i C_{01} . Parametri materijala za razmatrano stanje naprezanja *Mooney – Rivlin* materijalnog modela i koeficijent $R2$ prikazani su u tablici 6.

Na slici 70. prikazna je eksperimentalna i identificirana ovisnost naprezanja o deformaciji. Vidljivo je da kalibrirana krivulja *Mooney – Rivlin* materijalnog modela nešto položitija od one dobivene *neo–Hooke* materijalnim modelom. Stoga se može zaključiti da navedeni model bolje opisuje eksperimentalne podatke od *neo–Hooke* hiperelastičnog modela, što potvrđuje i vrijednost koeficijenta kalibracije. Kako ovaj model sadrži dva parametra materijala to je bilo i za očekivati, no rezultati i dalje nisu zadovoljavajući. Primjećuje se da ni jedan od navedena dva modela ne može pratiti zakrivljenost krivulje dobivene eksperimentalnim podacima. Druckerov kriterij stabilnosti također je zadovoljen za pretpostavljane uvjete istezljivosti od -50% do 50% (slika 70.).


Slika 71. Kalibracija *Mooney – Rivlin* materijalnog modela za dvoosno stanje naprezanjaTablica 6. Parametri materijala i koeficijent *R2* za *Mooney – Rivlin* materijalni model pri dvoosnom stanju naprezanja

C_{10}	$6,41591 \times 10^{-15}$
C_{01}	0,038941
$R2$	0,878

Slika 72. Provjera Druckerovog kriterija stabilnosti za *Mooney – Rivlin* materijalni model

9.3. Kalibracija hiperelastičnog materijalnog modela: *Ogden*

Na slici 73. prikazana je identificirana krivulja *Ogden* materijalnog modela. Uzeta je polinomna funkcija prvog reda (tj. $N=1$) za ravninsko dvoosno stanja naprezanja. Pripadajući parametri materijala koji opisuju odziv materijala za navedeni konstitutivni zakon su μ_1 (μ_1) i α_1 (α_1). Iz dijagrama vidljivo je da kalibracija *Ogden* modela poprilično dobro opisuje ponašanje materijala dobiveno eksperimentalnim ispitivanjem.

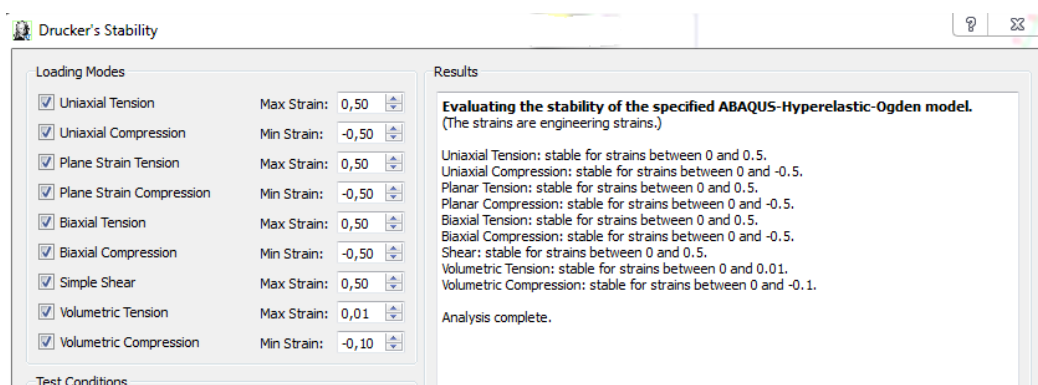


Slika 73. Kalibracija *Ogden* ($N=1$) materijalnog modela pri dvoosnom stanju naprezanja

U tablici 7. prikazane su vrijednosti parametara materijala koje najbolje opisuju dobiveno eksperimentalno ponašanje materijala. Uspoređujući koeficijent kalibracije ($R^2=0,993$) s prethodna dva materijalna modela može se zaključiti da ovaj model najbolje opisuje eksperimentalne podatke. Provjerom Druckerovog kriterija stabilnosti ustanovljeno je da je model stabilan za sva opterećenja u području $-0.5 \leq \varepsilon \leq 0.5$ (slika 74.).


Tablica 7. Parametri materijala i koeficijent R^2 za *Ogden* ($N=1$) materijalni model pri dvoosnom stanju naprezanja

μ_1	0,0401562
α_1	-9,19734
R^2	0,993



Slika 74. Provjera Druckerovog kriterija stabilnosti za Ogden ($N=1$) materijalni model

Prethodno je utvrđeno da dvoparametarski ($N=1$) Ogden model vrlo dobro opisuje eksperimentalne podatke s koeficijentom kalibracije $R^2=0,993$. Stoga je napravljena identifikacija parametara materijala konstitutivnog zakona Ogden definiranog polinomom drugog stupnja ($N=2$). Pretpostavka je da će predloženi model bolje opisati ponašanje ispitivanog hiperelastičnog materijala (tj. svinjske aorte). Na slici 75. prikazana je kalibracija Ogden ($N=2$) materijalnog modela za dvoosno stanje naprezanja i pripadajući iznosi parametara materijala μ_1 (μ_1), α_1 (α_1), μ_2 (μ_2) i α_2 (α_2).

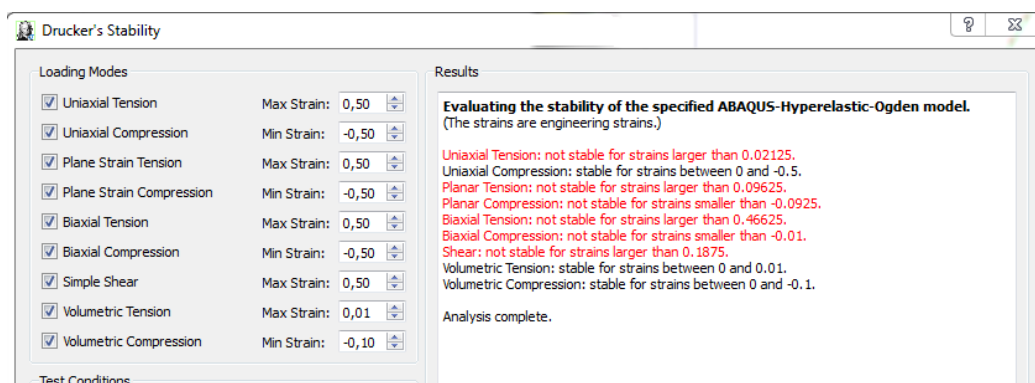


Slika 75. Kalibracija Ogden ($N=2$) materijalnog modela za dvoosno stanje naprezanja

Identificirani parametri materijala za razmatrana stanja naprezanja *Ogden* materijalnog modela te koeficijent kalibracije prikazani su u Tablica 8. Vidljivo je besprijekorno poklapanje, što znači da četveroparametarski ($N=2$) *Ogden* model može u potpunosti opisati dobivene eksperimentalne podatke što potvrđuje i koeficijent kalibracije $R^2=1$. No, provjerom Druckerovog kriterija stabilnosti ustanovljeno je da model nije stabilan za većinu stanja opterećenja u zadanom području deformacije $-0.5 \leq \varepsilon \leq 0.5$ [Slika 76.]. Štoviše, ni promjenom raspona deformacije ne može se mnogo utjecati na stabilnost materijala jer postaje nestabilan već pri vrlo malim vrijednostima (npr. za biaksijalno tlačno opterećenje je nestabilan već pri 1% deformacije). U skladu s navedenim kriterijima kalibracije materijalnog modela može se zaključiti da četveroparametarski *Ogden* model nije prihvatljiv za daljnju primjenu.

Tablica 8. Parametri materijala i koeficijent R^2 za *Ogden* ($N=2$) materijalni model pri dvoosnom stanju naprezanja

μ_1	0,876687
α_1	0,201523
μ_1	-0,857962
α_1	2,20707
R^2	1



Slika 76. Provjera Druckerovog kriterija stabilnosti za *Ogden* ($N=2$) materijalni model

9.4. Diskusija

Ukoliko se kod kontrole Druckerovog kriterija stabilnosti raspon deformacije poveća na 100% u tlačnom i vlačnom području, dolazi do pojave nestabilnosti materijala za određena stanja naprezanja. Konkretno, gubitak stabilnosti najprije je primjećen kod tlačnog opterećenja. Npr. kod *neo - Hooke* i *Ogden* modela se stabilnost materijala najprije gubi pri biaksijalnom tlačnom opterećenju, a kod *Mooney – Rivlin* modela pri tlačnom opterećenju za ravninsko stanje deformacije. U tablici 8. navedene su vrijednosti koeficijenta determinacije i postotak deformacije kod koje materijal više nije potpuno stabilan za tri korištena konstitutivna materijalna modela.

Tablica 9. Vrijednosti koeficijenta R^2 i stabilnost korištenih materijalnih modela

	<i>R² Fitness</i>	Stabilnost
<i>neo – Hooke</i>	0,782	do 84% ϵ
<i>Mooney – Rivlin</i>	0,878	do 96,5% ϵ
<i>Ogden (N=1)</i>	0,993	do 69,75% ϵ
<i>Ogden (N=2)</i>	1	do 1% ϵ

Na temelju prikazanog može se zaključiti da se dvoparametarski *Ogden (N=1)* materijalni model može koristiti u numeričkim analizama jer prilično dobro aproksimira ponašanje biološkog mekog tkiva (svinjske aorte) i stabilan je prema Druckerovom kriteriju u širokom području deformacije. Na slici 74. prikazana je identifikacija *Ogden* materijalnog modela polinomnom funkcijom drugog reda. Materijalni model više polinomne forme – *Ogden (N=2)* bolje prati trend krivulje, ali se gubi stabilnost materijala te iz tog razloga nije prihvatljiv za primjenu u numeričkim simulacijama. Provjereni su i ostali dostupni modeli no nije primijećeno bolje opisivanje eksperimentalnih rezultata (uz uvjet Druckerove stabilnosti materijala) u odnosu na *Ogden* model.

10. ZAKLJUČAK

Kako bi se bolje razumjele posljedice bolesti krvnih žila postoji potreba za provedbom mehaničkih ispitivanja na uzorcima s ciljem određivanja pouzdanijih svojstava materijala. Kod pretkliničkih istraživanja krvnih žila koriste se životinjski modeli. Mnoga dosadašnja istraživanja provedena su na modelima svinjskih žila pošto se pokazalo da su određene fiziološke i anatomske značajke vrlo slične ljudskim žilama.

Kao biološko tkivo, krvne žile su nehomogeni materijal, anizotropnih svojstava, te su eksperimentalna ispitivanja na njima relativno novo područje. Pregledom dosadašnjih istraživanja utvrđeno je da postoji relativno mali broj biaksijalnih eksperimenata na biološkim tkivima, a naročito krvnim žilama. U skladu s time, vrlo je malo podataka o mehaničkim svojstvima krvnih žila. Zbog toga, svako takvo eksperimentalno ispitivanje je od posebnog značaja te pridonosi novim saznanjima. Poznavanje biomehaničkih karakteristika stijenki krvnih žila vrlo je važno za što točniji opis konstitutivnih modela, te primjenu metode konačnih elemenata.

U ovom radu analizirana su četiri ravninska dvoosna eksperimenta na uzorcima pripremljenim od svinjske aorte. Mjerenja pomaka i deformacija provedena su videoekstenzometrom i metodom korelacije digitalne slike, na tri uzorka. Kod četvrtog uzorka pomaci i deformacije određeni su samo DIC metodom na cijeloj površini uzorka kako bi se odredio utjecaj prihvata na izmjereno polje pomaka i deformacija.

Primjena DIC metode omogućila je dobivanje cijelog polja pomaka i deformacija na površini uzoraka. Za analizu je korišten regularizacijski RT3-DIC algoritam koji filtrira sve fluktuacije koje nisu mehanički podatljive [24]. Utjecaj filtriranja ovisi o ulaznim (regularizacijskim) parametrima. Za dobivanje najpouzdanijih rezultata potrebno je pravilno zadati navedene parametre. U tom smislu, provedena je parametarska analiza rezolucije pomaka. Odabrana regularizacijska dužina za unutrašnje čvorove iznosi $l_m = 128$ piksela, a za vanjske čvorove $l_b = 64$ piksela (odabrani omjer regularizacijskih dužina je $l_b / l_m = 1/2$).

Polja deformacija izmjerena DIC metodom uspoređena su s deformacijama dobivenim videoekstenzometrom. Bitno je naglasiti da je određivanjem mjerne nesigurnosti utvrđeno je da DIC metoda daje pouzdanije rezultate. Stoga su u daljnjoj analizi korišteni podaci dobiveni mjerenjem cijelog polja pomaka. U rezultatima su uz dijagrame usporedbe dviju metoda prikazani i $F-\varepsilon$ dijagrami za svaku os opterećenja te dijagrami promjene deformacija

dobiveni DIC metodom. Za svaki od uzoraka prikazani su prethodno navedeni dijagrami te su izvedeni zaključci. Provedbom dvoosnog eksperimenta i uzimanjem u obzir orijentacije uzoraka dokazana je anizotropnost tkiva. Histereze u rezultatima upućuju na blagu viskoelastičnost tkiva (pseudoelastičnost). Primjetno je i povećanje deformacije kroz cikluse opterećenja što dokazuje omekšavanje tkiva (poznato kao *Mullins-ov efekt*). Tijekom biaksijalnih testova pojavljuju se i posmična naprezanja koja se ne mogu kontrolirati tijekom ispitivanja. Mnogi autori ih potpuno zanemaruju, pod pretpostavkom da ona ne postoje (jer su jako mala), ali to nije u potpunosti točno [14]. No, ona se mogu svesti na minimum i time zanemariti, ukoliko se ispitni uzorci pripreme i ispituju na odgovarajući način (prema literaturi [14],[53]), a koji je opisan i korišten u ovom radu. Usporednim prikazima deformacija vidi se utjecaj posmičnih naprezanja. Kod četvrtog uzorka je promatranjem generiranih polja deformacija utvrđeno da postoje lokalizacije deformacija koje su posljedica utjecaja prihvata. U skladu s time, kod budućih ispitivanja (ukoliko se mjeri široko polje deformacija kao kod ovog uzorka) bilo bi poželjno postaviti više udica (prihvata), kao što je predloženo u literaturi [53].

Za opisivanje ponašanja bioloških mekih tkiva najčešće se upotrebljavaju hiperelastični materijalni modeli. Danas ih ima mnogo, jednostavni su za korištenje i implementirani su u programske pakete koji rade na principu metode konačnih elemenata (*Abaqus*, *ANSYS*, *ADINA* i dr.). U ovom radu identificiranje parametara materijala pokazano je za tri hiperelastična materijalna modela koji se u praksi najčešće primjenjuju: *neo-Hooke*, *Mooney-Rivlin* i *Ogden*. Za identifikaciju u ovom radu korišten je komercijalno dostupan programski paket *MCalibration*, v.3.1.0. Kalibracijom (prilagodbom) materijalnih modela eksperimentalnim podacima utvrđeno je da od navedena tri modela *Ogden* model najbolje opisuje dobivene podatke. Također, provjerom Druckerovog kriterija stabilnosti ustanovljeno je da daje stabilan materijal za sve vrste opterećenja (jednoosno, dvoosno, ravninsko stanje deformacija). Za implementaciju materijalnog modela u neki od navedenih programskih paketa (koji se temelje na MKE) i primjenu u numeričkim analizama, to je vrlo bitna činjenica. Točnost rezultata dobivenih numeričkim metodama prvenstveno ovisi o kvaliteti proračunskog modela, stoga je pravilan izbor konstitutivnog materijalnog modela i određivanje koeficijenata najvažniji zadatak. Ispravnim modeliranjem moguće je postići veliku točnost [39]. Naravno, rezultate analiza svakako uvijek treba uzeti s oprezom i kritički ih razmotriti.

LITERATURA

- [1] Index, Zdravlje i medicina, Bolesti modernog čovjeka – bolesti srca i krvnih žila, Nina Pintar, <http://biologija.com.hr/modules/AMS/article.php?storyid=8976> (16.10.2015.)
- [2] Yamada, H., Strength of Biological Materials, Baltimore, Williams and Wilkins, 1970, pp. 113.
- [3] Carmines, D. V., McElhaney J. H. and R. Stack, A piece-wise non-linear elastic stress expression of human and pig coronary arteries tested in vitro, J. Biomech. 24:899–906, 1992.
- [4] van Andel, C. J., Pistecky P. V. and C. Borst, Mechanical properties of porcine and human arterie: Implications for coronary anastomotic connectors. Ann. Thorac. Surg. 76:58–65, 2003.
- [5] Schulze-Bauer, C. A., Morth J. C. and Holzapfel G. A., Passive biaxial response of aged human iliac arteries. ASME J. Biomech. Eng. 125:395–406, 2003.
- [6] Lally C., Reid A.J., Prendergast P.J., Elastic behaviour of porcine coronary artery tissue under uniaxial and equibiaxial tension, Annals of Biomedical Engineering, 2004.
- [7] Claes E., Atienza M. J., Guinea G., Rojo J. F., Bernal J. Revuelta M. J., Mechanical Properties of Human Coronary Arteries, 2015.
- [8] Zemanek M., Bursa J., Detak M., Biaxial tension tests with soft tissues of arterial wall, Engineering Mechanics, 2009.
- [9] Sommer G., Holzapfel G.A., 3D constitutive modeling of the biaxial mechanical response of intact and layer dissected human carotid arteries, Journal of the mechanical behaviour of biomedical materials, 2012.
- [10] Schriefl A., Schmidt T., Balzani D., Sommer G., Holzapfel G.A., Selective enzymatic removal of elastin and collagen from human abdominal aortas: Uniaxial mechanical response and constitutive modeling, Elsevier Ltd., 2015.
- [11] Sommer G., Schriefl A.J., Andrä M., Sacherer M., Viertler C., Wolinski M., Holzapfel G.A., Biomechanical properties and microstructure of human ventricular myocardium, 2015.
- [12] G. Sommer, A. Schriefl, G. Zeindlinger, A. Katzensteiner, H. Ainödhofer, A. Saxena, et al., Multiaxial mechanical response and constitutive modeling of esophageal tissues: impact on esophageal tissue engineering, Acta Biomater. 9(2013). 9379-9091

- [13] Sommer G., Eder M., Kovacs L., Pathak H., Bonitz L., Regitnig P., Holzapfel G.A., Mueller C., Multiaxial mechanical properties and constitutive modeling of human adipose tissue: A basis for preoperative simulations in plastic and reconstructive surgery, 2013.
- [14] Sommer G., Haspinger, D., Viertler C., Regitnig P., Andra M., Sacherer M., Holzapfel G.A.: Quantification of Shear Deformations and Corresponding Stresses in the Biaxially Tested Human Myocardium, 2015.
- [15] Yosibash, Z., Trabelsi, N., Milgrom, C.: Reliable simulations of the human proximal femur by high-order finite element analysis validated by experimental observations. *Journal of Biomechanics*. 2007;40:3688-3699.
- [16] Yoneyama, S., Murasawa, Go. Digital image correlation. *Encyclopedia of Life Support Systems (EOLSS) – Experimental Mechanics*, 2007.
- [17] Zhang, D., Arola, D.D. Applications of digital image correlation to biological tissues. *Journal of Biomedical Optics*. 2004;9(4):691-699.
- [18] Luyckx, T., Verstraete, M., De Roo, Karel., De Waele, Wim., Bellemans, J., Victor, Jan. Digital image correlation as a tool for three-dimensional strain analysis in human tendon tissue. *Journal of Experimental Orthopaedics*. 2014;1(7):9.
- [19] Moerman K. M., Holt C. A., Evans S. L. Simms C. K. Digital image correlation and finite element modelling as a method to determine mechanical properties of human soft tissue in vivo. *Journal of Biomechanics*. 2009;42:1150-1153.
- [20] Zhang, D., D. Arola, D., Eggerton, C. D. A new fast-search strategy for digital image correlation, *Conf. on Theoretical, Experimental and Computational Mechanics*. 2002.
- [21] Zhang, D., D. Arola, D., Eggerton, BMES/IEEE Joint Meeting. 2002;1276-1277.
- [22] Zhang, D., D. Arola, D., Eggerton, C., D. An application of digital image correlation to bovine aorta. *Conf. On Theoretical, Experimental and Computational Mechanics*. 2002.
- [23] Surjak, M., Validacija numeričkih modela mehaničkog ponašanja životinjskih i ljudskih kostiju, doktorski rad, Zagreb, 2015.
- [24] Tomičević Z., Pamuković F., Surjak M., Kodvanj J., Primjena regularizacije na korelaciju digitalne slike, *Peti susret Hrvatskog društva za mehaniku, Terme Jezerčica, Donja Stubica, lipanj 2013*.
- [25] <https://hr.wikipedia.org/wiki/Arterija> (10.11.2015.)
- [26] <http://wol.jw.org/hr/wol/d/r19/lp-c/102001208#h=11> (10.11.2015.)
- [27] <file:///E:/Downloads/Srce+2014.pdf> (10.11.2015.)

- [28] <http://www.wisegeek.com/what-is-the-difference-between-arteries-and-veins.htm#didyouknowout> (10.11.2015.)
- [29] M. M. Swindle, A. Makin, A. J. Herron, F. J. Clubb Jr., K. S. Frazier, Swine as models in biomedical research and toxicology testing, The American College of Veterinary Pathologists, 2012.
- [30] Carolien J. van Andel, MSc, PhD, Peter V. Pistecky, MSc, and Cornelius Borst, MD, PhD, Mechanical Properties of Porcine and Human Arteries: Implications for Coronary Anastomotic Connectors, The Society of Thoracic Surgeons, 2003.
- [31] Jay D. Humphrey, Cardiovascular Solid Mechanics, Springer – Verlag New York, 2002.
- [32] <https://polymerfem.com/content.php?71-material-models> (28.1.2016.)
- [33] https://en.wikipedia.org/wiki/Hyperelastic_material (28.1.2016.)
- [34] Karšaj I., Numeričko modeliranje procesa deformiranja uz pretpostavku velikih deformacija, doktorski rad, Zagreb, 2006.
- [35] Alfirević I., Uvod u tenzore i mehaniku kontinuuma, Golden marketing, Zagreb, 2003.
- [36] https://en.wikipedia.org/wiki/Neo-Hookean_solid (12.2.2016.)
- [37] https://en.wikipedia.org/wiki/Mooney%E2%80%93Rivlin_solid (12.2.2016.)
- [38] [https://en.wikipedia.org/wiki/Ogden_\(hyperelastic_model\)](https://en.wikipedia.org/wiki/Ogden_(hyperelastic_model)) (12.2.2016.)
- [39] Čakmak D., Numerička analiza krutosti gumenog zgloba rastojnika-prigušivača, diplomski rad, Zagreb, 2015.
- [40] <https://sourceforge.net/directory/os:windows/?q=hyperfit> (12.2.2016.)
- [41] <https://polymerfem.com/content.php?9-Material-Model-Calibration-MCalibration> (12.2.2016.)
- [42] <https://polymerfem.com/showthread.php?2834-How-to-request-a-trial-version-of-the-standard-MCalibration-and-PolyUMod-Software> (12.2. 2016.)
- [43] MCalibration Manual, Version 2.5.7., Veryst Engineering, LLC, 2010.
- [44] https://en.wikipedia.org/wiki/Drucker_stability (12.2.2016.)
- [45] <http://www.3d-deformacije.com/staticki-vlacni-pokus> (1.12.2015.)
- [46] <http://www.3r-labo.com/en/extensometers/extensometers-clip-on> (17.1.2016.)
- [47] <https://en.wikipedia.org/wiki/Extensometer> (17.1.2016.)
- [48] <http://www.azom.com/article.aspx?ArticleID=6052> (17.1. 2016.)
- [49] <http://www.mathworks.com/matlabcentral/fileexchange/50994-digital-image-correlation-and-tracking> (15.12.2015.)

-
- [50] Bubalo A., Određivanje polja pomaka vrška pukotine digitalnom korelacijom slike, Završni rad, Zagreb, 2011.
- [51] Tomicevic Z., Hild F. and Roux S., Mechanics-aided digital image correlation, 2013., web stranica:
<http://sdj.sagepub.com/content/early/2013/06/11/0309324713482457>
- [52] Tomičević Z., Identifikacija mehaničkih svojstava nodularnog lijeva kod višeosnih opterećenja, Međunarodni dvojni doktorat znanosti, Zagreb, 2015.
- [53] Eilaghi, A., J. G. Flanagan, G. W. Brodland, and C. R. Ethier. Strain uniformity in biaxial specimens is highly sensitive to attachment details. *J. Biomech. Eng.* 131:0910031–0910037, 2009.
- [54] G. A. Holzapfel, G. Sommer, P. Regitnig, Anisotropic mechanical properties of tissue components in human atherosclerotic plaques, *J. Biomech, Eng.*, 2004.
- [55] G.A. Holzapfel, G. Sommer, C.T. Gasser, P. Regitnig, Determination of layer-specific mechanical properties of human coronary arteries with nonatherosclerotic intimal thickening, and related constitutive modeling, *Am. J. Physiol. Heart Circ. Physiol.* 289 (2005) H2048–2058.


PRILOZI

- I. CD-R disc
- II. Rezultati ispitivanja ostalih uzoraka


Rezultati ispitivanja ostalih uzoraka

AORTA 2


1. Prekondicioniranje 1 (P1)




Slika 77. Usporedni prikaz promjene deformacije ε u vremenu t za Prekondicioniranje 1 uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar




Slika 78. Dijagram promjene sile F za Prekondicioniranje 1 uzorka AORTA 2 u aksijalnom (A) i transverzalnom (T) smjeru




Slika 79. Usporedni prikaz promjene deformacija ε za *Prekondicioniranje 1* uzorka AORTA 2




Slika 80. Dijagram sila F – deformacija ε za *Prekondicioniranje 1* uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru

2. Test 1 (T1)


Slika 81. Usporedni prikaz promjene deformacije ε u vremenu t za Test 1 uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar




Slika 82. Dijagram promjene sile F za Test 1 uzorka AORTA 2 u aksijalnom (A) i transverzalnom (T) smjeru




Slika 83. Usporedni prikaz promjene deformacija ε za *Test 1* uzorka AORTA 2




Slika 84. Dijagram sila F – deformacija ε za *Test 1* uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru




Slika 85. Mjerena polja pomaka za vršnu vrijednost opterećenja za *Test 1* uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru




Slika 86. Mjerena polja deformacija za vršnu vrijednost opterećenja za *Test 1* uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru

3. Prekondicioniranje 2 (P2)


Slika 87. Usporedni prikaz promjene deformacije ε u vremenu t za *Prekondicioniranje 2* uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar




Slika 88. Dijagram promjene sile F za *Prekondicioniranje 2* uzorka AORTA 2 u aksijalnom (A) i transverzalnom (T) smjeru




Slika 89. Usporedni prikaz promjene deformacija ε za *Prekondicioniranje 2* uzorka AORTA 2




Slika 90. Dijagram sila F – deformacija ε za *Prekondicioniranje 2* uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru

4. Test 2 (T2)


Slika 91. Usporedni prikaz promjene deformacije ε u vremenu t za Test 2 uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar




Slika 92. Dijagram promjene sile F za Test 2 uzorka AORTA 2 u aksijalnom (A) i transverzalnom (T) smjeru




Slika 93. Usporedni prikaz promjene deformacija ε za *Test 2* uzorka AORTA 2



Slika 94. Dijagram sila F – deformacija ε za *Test 2* uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru




Slika 95. Mjerena polja pomaka za vršnu vrijednost opterećenja za *Test 2* uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru




Slika 96. Mjerena polja deformacija za vršnu vrijednost opterećenja za *Test 2* uzorka AORTA 2 u a) aksijalnom (A) i b) transverzalnom (T) smjeru


AORTA 3

1. Prekondicioniranje 1 (P1)


Slika 97. Usporedni prikaz promjene deformacije ε u vremenu t za *Prekondicioniranje 1* uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar




Slika 98. Dijagram promjene sile F za *Prekondicioniranje 1* uzorka AORTA 3 u aksijalnom (A) i transverzalnom (T) smjeru




Slika 99. Usporedni prikaz promjene deformacija ε za *Prekondicioniranje 1* uzorka AORTA 3




Slika 100. Dijagram sila F – deformacija ε za *Prekondicioniranje 1* uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru

2. Test 1 (T1)


Slika 101. Usporedni prikaz promjene deformacije ε u vremenu t za Test 1 uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar




Slika 102. Dijagram promjene sile F za Test 1 uzorka AORTA 3 u aksijalnom (A) i transverzalnom (T) smjeru




Slika 103. Usporedni prikaz promjene deformacija ϵ za *Test 1* uzorka AORTA 3




Slika 104. Dijagram sila F – deformacija ϵ za *Test 1* uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru




Slika 105. Mjerena polja pomaka za vršnu vrijednost opterećenja za *Test 1* uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru




Slika 106. Mjerena polja deformacija za vršnu vrijednost opterećenja za *Test 1* uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru

3. Prekondicioniranje 2 (P2)


Slika 107. Usporedni prikaz promjene deformacije ε u vremenu t za Prekondicioniranje 2 uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar




Slika 108. Dijagram promjene sile F za Prekondicioniranje 2 uzorka AORTA 3 u aksijalnom (A) i transverzalnom (T) smjeru




Slika 109. Usporedni prikaz promjene deformacija ε za *Prekondicioniranje 1* uzorka AORTA 3




Slika 110. Dijagram sila F – deformacija ε za *Prekondicioniranje 2* uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru

4. Test 2 (T2)


Slika 111. Usporedni prikaz promjene deformacije ε u vremenu t za Test 2 uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar




Slika 112. Dijagram promjene sile F za Test 2 uzorka AORTA 3 u aksijalnom (A) i transverzalnom (T) smjeru




Slika 113. Usporedni prikaz promjene deformacija ε za *Test 2* uzorka AORTA 3



Slika 114. Dijagram sila F – deformacija ε za *Test 2* uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru




Slika 115. Mjerena polja pomaka za vršnu vrijednost opterećenja za *Test 2* uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru




Slika 116. Mjerena polja deformacija za vršnu vrijednost opterećenja za *Test 2* uzorka AORTA 3 u a) aksijalnom (A) i b) transverzalnom (T) smjeru

AORTA 4


1. Prekondicioniranje 1 (P1)




Slika 117. Usporedni prikaz promjene deformacije ε u vremenu t za *Prekondicioniranje 1* uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar




Slika 118. Dijagram promjene sile F za *Prekondicioniranje 1* uzorka AORTA 4 u aksijalnom (A) i transverzalnom (T) smjeru




Slika 119. Usporedni prikaz promjene deformacija ε za *Prekondicioniranje 1* uzorka AORTA 4




Slika 120. Dijagram sila F – deformacija ε za *Prekondicioniranje 1* uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru

2. Test 1 (T1)


Slika 121. Usporedni prikaz promjene deformacije ε u vremenu t za *Test 1* uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar




Slika 122. Dijagram promjene sile F za *Test 1* uzorka AORTA 4 u aksijalnom (A) i transverzalnom (T) smjeru




Slika 123. Usporedni prikaz promjene deformacija ϵ za Test 1 uzorka AORTA 4




Slika 124. Dijagram sila F – deformacija ϵ za Test 1 uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru




Slika 125. Mjerena polja pomaka za vršnu vrijednost opterećenja za *Test 1* uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru




Slika 126. Mjerena polja deformacija za vršnu vrijednost opterećenja za *Test 1* uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru

3. Prekondicioniranje 2 (P2)


Slika 127. Usporedni prikaz promjene deformacije ε u vremenu t za *Prekondicioniranje 2* uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar




Slika 128. Dijagram promjene sile F za *Prekondicioniranje 2* uzorka AORTA 4 u aksijalnom (A) i transverzalnom (T) smjeru




Slika 129. Usporedni prikaz promjene deformacija ε za *Prekondicioniranje 2* uzorka AORTA 4




Slika 130. Dijagram sila F – deformacija ε za *Prekondicioniranje 2* uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru

4. Test 2 (T2)


Slika 131. Usporedni prikaz promjene deformacije ε u vremenu t za Test 2 uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru za DIC i videoekstenzometar



Slika 132. Dijagram promjene sile F za Test 2 uzorka AORTA 4 u aksijalnom (A) i transverzalnom (T) smjeru



Slika 133. Usporedni prikaz promjene deformacija ε za Test 2 uzorka AORTA 4



Slika 134. Dijagram sila F – deformacija ε za Test 2 uzorka AORTA 4 u a) aksijalnom (A) i b) transverzalnom (T) smjeru